

**OPTIMASI NAÏVE BAYES MENGGUNAKAN GENETIC
ALGORITHM UNTUK PREDIKSI KEBAKARAN HUTAN**



TESIS

DUWI CAHYA PUTRI BUANI

14000815

**PROGRAM PASCASARJANA MAGISTER ILMU KOMPUTER
SEKOLAH TINGGI MANAJEMAN INFORMATIKA DAN KOMPUTER**

NUSA MANDIRI

JAKARTA

2014

SURAT PERNYATAAN ORISINALITAS

Yang bertanda tangan dibawah ini :

Nama : Duwi Cahya Putri Buani

NIM : 14000815

Program Studi : Magister Ilmu Komputer

Jenjang : Strata Dua (S2)

Konsentrasi : *Management Information System*

Dengan ini menyatakan bahwa tesis yang telah saya buat dengan judul: “Optimasi Naïve Bayes Menggunakan Genetic Algorithm Untuk Prediksi Kebakaran Hutan” adalah hasil karya sendiri, dan semua sumber baik yang kutip maupun yang dirujuk telah saya nyatakan dengan benar dan tesis belum pernah diterbitkan atau dipublikasikan dimanapun dan dalam bentuk apapun.

Demikianlah surat pernyataan ini saya buat dengan sebenar-benarnya. Apabila dikemudian hari ternyata saya memberikan keterangan palsu dan atau ada pihak lain yang mengklaim bahwa tesis yang telah saya buat adalah hasil karya milik seseorang atau badan tertentu, saya bersedia diproses baik secara pidana maupun perdata dan kelulusan saya dari Program Pascasarjana Magister Ilmu Komputer Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri dicabut/dibatalkan.

Jakarta, 28 Februari 2015

Yang Menyatakan,



Duwi Cahya Putri Buani

HALAMAN PENGESAHAN

Tesis ini diajukan oleh :

Nama : Duwi Cahya Putri Buani
NIM : 14000815
Program Studi : Magister Ilmu Komputer
Jenjang : Strata Dua (S2)
Konsentrasi : *Management Information System*
Judul Tesis : Optimasi Naïve Bayes Menggunakan Genetic
Algorithm Untuk Prediksi Kebakaran Hutan


Telah Berhasil Dipertahankan dihadapan Dewan Penguji dan diterima sebagai bagian persyaratan yang diperlukan untuk memperoleh gelar Magister Ilmu Komputer (M.Kom) pada Program Pascasarjana Magister Ilmu Komputer Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri (STMIK Nusa Mandiri).

Jakarta, 13 Maret 2015

Pascasarjana Magister Ilmu Komputer

STMIK Nusa Mandiri

Direktur



Prof. Dr. Ir Kaman Nainggolan MS

DEWAN PENGUJI

Penguji I : Dr. Sularso Budilaksono


.....

Penguji II : Dr. Windu Gata, M.Kom


.....

Penguji III / Pembimbing : Dr Dana Indra Sensuse, M.LIS, Ph.D





LEMBAR KONSULTASI BIMBINGAN TESIS

Pascasarjana Magister Ilmu Komputer

STMIK Nusa Mandiri

Nama : Duwi Cahya Putri Buani
NIM : 14000815
Dosen Pembimbing : Dr Dana Indra Sensuse, M.LIS, Ph.D
Judul Tesis : Optimasi Naïve Bayes Menggunakan
Genetica Algorithm untuk Prediksi
Kebakaran Hutan



No	Tanggal Bimbingan	Materi Bimbingan	Paraf dosen Pembimbing
1	6 November 2014	Pengajuan Judul	
2	19 November 2014	Pengajuan Judul dan Bab I	
3	14 Desember 2014	Pengajuan Judul dan Bab I	
4	21 Desember 2014	Pengajuan Bab II	
5	25 Januari 2015	Revisi Bab II dan Pengajuan Bab III	
6	22 Februari 2015	Revisi Bab III dan Pengajuan Bab IV	
7	28 Februari 2015	Revisi Bab IV, Pengajuan Bab V dan ACC	

Bimbingan dimulai pada tanggal : 06 November 2014
Bimbingan diakhiri pada tanggal : 28 Februari 2015
Jumlah pertemuan : 7

Jakarta, 28 Februari 2015

Dosen Pembimbing

(Dr Dana Indra Sensuse, M.LIS, Ph.D)

KATA PENGANTAR

Puji syukur alhamdullillah, penulis panjatkan kehadiran Allah SWT, yang telah melimpahkan rahmat dan karunia-Nya, sehingga pada akhirnya penulis dapat menyelesaikan Skripsi ini dengan baik. Di mana skripsi ini penulis sajikan dalam bentuk buku yang sederhana. Adapun judul penulisan tesis, yang penulis ambil adalah sebagai berikut: "Optimasi *Naïve Bayes* Menggunakan *Genetica Algorithm* untuk Prediksi Kebakaran Hutan".

Tujuan penulisan tesis ini dibuat sebagai salah satu syarat kelulusan Program Pasca Sarjana (S2) STMIK NUSA MANDIRI. Sebagai bahan penulisan diambil berdasarkan hasil penelitian (eksperimen), observasi dan beberapa sumber literatur yang mendukung penulisan ini. Penulis menyadari bahwa tanpa bimbingan dan dorongan dari semua pihak, maka penulisan skripsi ini tidak akan lancar. Oleh karena itu pada kesempatan ini, izinkanlah penulis menyampaikan ucapan terima kasih kepada:

1. Bapak Dr. Dana Indra Sensuse, Selaku Pembimbing Tesis yang telah menyediakan waktu, pemikiran dan tenaga dalam membimbing penulis dalam menyelesaikan tesis ini.
2. Ibunda, Almarhum Painem yang penulis sayangi serta Keluarga yang telah memberikan dukungan Moral Kepada Penulis.
3. Saudara Kembar saya Duwi Cahya Putri Pratiwi, S.Kom yang selalu memberi motivasi agar penulisan ini selesai.
4. Seluruh Staf Pengajar (Dosen) Program Pascasarjana Magister Ilmu Komputer Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri yang telah memberikan pelajaran yang berarti bagi penulis selama menempuh studi
5. Seluruh Rekan Kerja penulis di Bina Sarana Informatika yang telah banyak memberikan masukan – masukan yang bermanfaat pada penelitian ini;
6. Rekan – Rekan Seperjuangan, Ratih Yulia, Retno Sari, Nia Nuraeni dan Sutri Handayani yang selalu memberi motivasi agar penulisan ini selesai.

Serta semua pihak yang terlalu banyak untuk disebutkan satu persatu sehingga terwujudnya penulisan ini. Penulis menyadari bahwa penulisan tesis ini masih jauh sekali dari sempurna, untuk itu penulis mohon kritik dan saran yang bersifat membangun demi kesempurnaan penulis dimasa yang akan datang. Akhir kata semoga tesis ini dapat berguna bagi penulis khususnya dan bagi pembaca yang berminat umumnya.

Jakarta, Februari 2015

A handwritten signature in blue ink, appearing to read 'Dianing', with a stylized flourish at the end.

Penulis

**SURAT PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH
UNTUK KEPENTINGAN AKADEMIS**

Yang bertanda tangan dibawah ini :

Nama : Duwi Cahya Putri Buani
NIM : 14000815
Program Studi : Magister Ilmu Komputer
Jenjang : Strata Dua (S2)
Konsentrasi : *Management Information System*
Jenis Karya : Tesis

Demi pengembangan ilmu pengetahuan, dengan ini menyetujui untuk memberikan ijin kepada pihak Program Pascasarjana Magister Ilmu Komputer Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri (STMIK Nusa Mandiri) Hak Bebas Royalti Non-Eksklusif (Non-exclusive Royalti-Free Right) atas karya ilmiah kami yang berjudul : “Optimasi Naïve Bayes Menggunakan Genetic Algorithm Untuk Prediksi Kebakaran Hutan” beserta perangkat yang diperlukan (apabila ada). Dengan Hak Bebas Royalti Non-Eksklusif ini pihak STMIK Nusa Mandiri berhak menyimpan, mengalih media atau bentuk-kan, mengelolanya dalam pangkalan data (database), mendistribusikannya dan menampilkan atau mempublikasikannya di internet atau media lain untuk kepentingan akademis tanpa perlu meminta ijin dari kami selama tetap mencantumkan nama kami sebagai penulis/pencipta karya ilmiah tersebut. Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak STMIK Nusa Mandiri, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini. Demikian pernyataan ini saya buat dengan sebenarnya.

Jakarta, 28 Februari 2015

Yang Menyatakan



(Duwi Cahya Putri Buani)

ABSTRAK

Nama : Duwi Cahya Putri Buani
NIM : 14000815
Program Studi : Magister Ilmu Komputer
Jenjang : Strata Dua (S2)
Konsentrasi : *Management Information System*
Judul : “Optimasi Naïve Bayes Menggunakan Genetic Algorithm Untuk Prediksi Kebakaran Hutan”

Kebakaran hutan merupakan salah satu gangguan yang sangat besar terhadap ekosistem, sehingga perlu adanya pencegahan dini agar kebakaran tidak menjadi luas dan menjadi kebakaran hutan yang sangat besar dan sulit untuk dihentikan penyebarannya. Prediksi dini kebakaran hutan adalah salah satu cara untuk menangani masalah tersebut, penelitian sebelumnya telah membahas tentang prediksi kebakaran hutan ini, sehingga penulis ingin mengangkat kembali topik ini dengan menggunakan metode yang berbeda, penelitian ini menggunakan metode naïve bayes yang dioptimasi dengan menggunakan algoritma genetika. Hasil penelitian ini terbukti memiliki tingkat keakurasian yang tinggi. Penelitian dilakukan dengan menggunakan metode naïve bayes tanpa dilakukan dengan penambahan metode hasil dari penggunaan metode ini nilai akurasi 94,58% sedangkan nilai AUC(*Area Under Curva*) adalah 0,74 selanjutnya penulis melakukan eksperimen dengan menggunakan algoritma genetika sebagai fitur selection dari metode naïve bayes, dengan menggunakan model ini hasil akurasi meningkat menjadi 94,80 sedangkan nilai AUC(*Area Under Curva*) 0,97. Dari hasil tersebut dapat disimpulkan bahwa penelitian ini berhasil meskipun selisih nilai akurasi dan AUC(*Area Under Curva*) sangat tipis.

Kata Kunci : Data Mining, *Naïve Bayes*, Algoritma Genetika ,Kebakaran Hutan

ABSTRACT

Name : Duwi Cahya Putri Buani
NIM : 14000815
Study Of Program : Magister Ilmu Komputer
Levels : Strata Dua (S2)
Concentration : Management Information System
*Title : “Naïve Bayes Optimization Using Algorithm Genetic
for Prediction Forest Fire ”*

Forest fires are one of a very large disturbance to the ecosystem, so the need for early intervention in order to not become widespread fires and wildfires become very large and difficult to stop its spread. Early prediction of forest fires is one way to address the problem, previous studies have discussed about this forest fire prediction, so that the author wants to revive this topic by using different methods, this study uses naïve Bayes methods are optimized using a genetic algorithm. The results of this study proved to have a high degree of accuracy. The study was conducted by using the naïve Bayes methods without performed by the addition method results from the use of this method accuracy values 94.58% while the value of AUC (Area Under Curva) is further 0.74 authors conducted experiments using a genetic algorithm as Future selection of naïve Bayes methods , by using this model accuracy results increased to 94.80 while the value of AUC (Area Under Curva) 0.97. From these results it can be concluded that this study succeeded in spite of the difference in the value of accuracy and AUC (Area Under Curva) very thin.

Kata Kunci : *Data Mining, Naïve Bayes, Algorithm Genetic, Forest Fire*

DAFTAR ISI

Halaman Judul.....	i
Halaman Pernyataan Orisinalitas.....	ii
Halaman Pengesahan.....	iii
Lembar konsultasi.....	iv
Kata Pengantar.....	v
Lembar Persetujuan Publikasi.....	vii
Abstraksi.....	ix
Abstarct.....	x
Daftar Isi.....	xi
Daftar Tabel.....	xii
Daftar Gambar.....	xiii
DaftarLampiran.....	xiv
BAB I Pendahuluan.....	1
1.1.Latar Belakang.....	1
1.2.Identifikasi Masalah.....	2
1.3.Rumusan Masalah.....	3
1.4.Tujuan Penelitian.....	3
1.5.Manfa’at Penelitian.....	3
1.6.Ruang Lingkup.....	3
1.7.Sistematika Penulisan.....	4
BAB II Landasan Teori.....	6
2.1 Tinjauan Pustaka.....	6
2.2 Tinjauan Studi.....	22
2.3 Kerangka Pemikiran.....	24
2.4 <i>Prototype</i>	24
2.5 Hipotesa.....	25
BAB III Metode Penelitian.....	26
3.1 Jenis Penelitian.....	25

3.2 Pengumpulan Data.....	27
3.3 Pengolahan Data Awal.....	29
3.4 Metode yang Digunakan.....	32
3.5 Eksperimen dan Pengujian Metode.....	32
3.6 Evaluasi dan Validasi Hasil.....	34
3.7 <i>Prototype</i>	34
BAB IV Hasil dan Pembahasan.....	35
4.1 Hasil Eksperimen dan Pengujian.....	35
4.2 Pembahasan.....	35
4.3 Hasil Penelitian.....	50
4.4 Perancangan dan Pengujian <i>Prototype</i>	55
4.5 Implikasi Penelitian.....	59
BAB V Kesimpulan dan Saran.....	60
5.1 Kesimpulan.....	60
5.2 Saran.....	60
Daftar Pustaka.....	61
Daftar Riwayat Hidup.....	63
Lampiran.....	64

DAFTAR TABLE

	Halaman
Table 2.1 Model <i>Confussion Matrix</i>	19
Table 2.2 <i>Metric software quality assurance (SQA)</i>	21
Table 2.3 Kriteria Skala Penilaian.....	21
Table 2.4 <i>State of the art research</i> Prediksi Kebakaran Hutan.....	22
Table 3.1 Data Kebakaran Hutan Wilayah Timur Laut Portugal (Montensinho <i>Park</i>).....	28
Table 3.2 Attribut yang digunakan.....	31
Tabel 3.3 Spesifikasi <i>Software</i> dan <i>Hardware</i>	33
Table 4.1 Perhitungan Probabilitas Prior.....	36
Table 4.2 Perhitungan Probabilitas Posterior.....	38
Table 4.3 Data Forest Fair.....	43
Table 4.4 Hasil Confussion Matrix Naïve Bayes.....	52
Table 4.5 Hasil Confussion Matric NB + GA.....	53
Table 4.6 Nilai Akurasi dan AUC Hasil Pengujian NB dan NB+GA.....	54
Table 4.7 Hasil evaluasi SQA.....	56
Table 4.8 Hasil evaluasi SQA dalam penilaian skala <i>Likert</i>	57
Table 4.9 Hasil perhitungan Skala <i>Likert</i> Penelitian tiap Metrik.....	57

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Fire Weather Index Struktur.....	18
Gambar 2.2 Kerangka Pemikiran.....	24
Gambar 3.1 Tahapan Penelitian.....	27
Gambar 3.2 Model yang Diusulkan.....	32
Gambar 4.1 Model X-Validation.....	40
Gambar 4.2 Model Naïve Baye.....	41
Gambar 4.3 Hasil Akurasi Metode Naïve Bayes pada Rapid Miner.....	41
Gambar 4.4 Hasil AUC Menggunakan Naïve Bayes.....	42
Gambar 4.5 Koneksi Datasate dengan Optimaize Selection.....	48
Gambar 4.6 Evaluation Proses menggunakan X-Validation.....	48
Gambar 4.7 Model Optimasi Naive Bayes berbasis Algoritma Genetika.....	49
Gambar 4.8 Hasil Confussion Matrix dari model NB berbasis GA.....	49
Gambar 4.9 Hasil AUC Naive Bayes berbasis Algoritma Genetika.....	50
Gambar 4.10 <i>Confussion Metrix</i> Model Naïve Bayes.....	51
Gambar 4.11 Hasil Confusion Matrix Menggunakan Naïve Bayes berbasis Algoritma Genetika.....	52
Gambar 4.12 Curva AUC model Naïve Bayes.....	53
Gambar 4.13 Curva AUC model Naïve Bayes berbasis Algoritma Genetika.....	54
Gambar 4.14 <i>Prototype</i> Prediksi Kebakaran Hutan.....	55
Gambar 4.15 Grafik Perhitungan Skala Likert Penelitian Tiap Metrik.....	58

BAB I

PENDAHULUAN

1.1 Latar Belakang Penulisan

Kebakaran hutan merupakan salah satu gangguan yang sangat signifikan mengganggu perkembangan ekosistem. Perubahan iklim global merupakan salah satu pemicu terjadinya kebakaran hutan.

Studi sebelumnya telah menunjukkan bahwa ada hubungan antara kondisi meteorologi dengan kebakaran hutan. Hal ini diyakini dari variable meteorologi seperti suhu, relative kelembaban, kecepatan angin dan curah hujan (Cortez dan Morais, 2007; Amiro et al, 2004). Beberapa variable meteorologi menjadi indeks numerik perhitungan mereka. Sebuah contoh adalah kebakaran hutan di Kanada menggunakan indeks Cuaca (FWI).

Penggunaan *data mining* dengan model *Naïve Bayes* sebagai salah satu pilihan untuk memprediksi kebakaran hutan dapat menjadi alternatif pilihan yang tepat.

Peneliti sebelumnya yaitu Vasanth Iyer, S. Sitharama Iyengar, N. Paramesh, dan Garmiela Rhama Murty dengan judul penelitian *Machine Learning and Data Mining Algorithm for Predicting Accidental Small Forest Fires*, menggunakan Naïve Bayes dan *J48 Three Classifiers*. Yang membahas komparasi dua algoritma Naïve Bayes dan *J48 Three Classifiers*. Akurasi yang didapat dari prediksi kebakaran hutan kecil (*Accidental Small Forest*) *J48 Three Classifiers* memiliki akurasi 80% sedangkan Naïve Bayes 61 %. Sedangkan prediksi untuk keseluruhan kategori kebakaran untuk *J48 Three Classifiers* 72,1% sedangkan Naïve Bayes 51, 64% dilihat dari hasil akurasi maka akurasi *J48 Three Classifiers* lebih baik dari pada Naïve Bayes. Sehingga penulis mengangkat topik ini kembali tetapi bukan untuk memprediksi *Accidental Forest* dan *Small Forest* tetapi untuk memprediksi kebakaran kecil atau kebakaran besar dengan menggunakan algoritma yang sama yaitu algoritma Naïve Bayes yang dioptimasi dengan Algoritma Genetika.

Naïve Bayes adalah pengklasifikasian statistik yang dapat digunakan untuk memprediksi probabilitas keanggotaan suatu *class*. Naïve Bayes didasarkan pada teorema Bayes yang memiliki kemampuan klasifikasi serupa dengan *decision tree* dan neural network. Naïve Bayes terbukti memiliki akurasi dan kecepatan yang tinggi saat diaplikasikan ke dalam database dengan data yang besar (Kusrini dan E. T. Luthfi, 2009).

Naïve bayes merupakan algoritma klasifikasi data mining yang menganggap masing-masing atribut tidak saling berhubungan. Maka dari itu digunakan algoritma genetika untuk membantu naïve bayes dalam menentukan atribut-atribut yang harus digunakan sehingga dapat meningkatkan akurasi (Wahyuni, 2014).

1.2 Identifikasi Masalah

Dari latar belakang masalah diatas maka dapat diambil kesimpulan permasalahan penelitian sebelumnya adalah:

1. Algoritma Naïve Bayes memiliki celah yang memasukan semua atribut kedalam perhitungannya sehingga kurang efektif untuk memprediksi.
2. Algoritma Naïve Bayes tidak memandang keterkaitan antar atribut yang satu dengan yang lainnya (independensi). Jadi ketika ada datastate dengan jumlah atribut ratusanpun akan dihitung semuanya oleh Naïve Bayes.
3. Algoritma Naïve Bayes membutuhkan fitur seleksi, untuk menseleksi *attribut* yang akan digunakan dan salah satu fitur seleksi yang dapat digunakan adalah algoritma genetika.
4. Penelitian terdahulu telah memprediksi kebakaran hutan yang memiliki akurasi yang sangat rendah dengan menggunakan Naïve Bayes sehingga penulis mengoptimasi Naïve Bayes dengan Algoritma Genetika, serta penelitian terdahulu memiliki empat kelas prediksi, yaitu klas *Accidental*, *Small Fire*, *Medium Fire* dan *Large Fire*. Sedangkan penelitian ini hanya membagi data menjadi dua kelas yaitu kebakaran kecil dan kebakaran besar.

1.3 Rumusan Masalah

Apakah prediksi dengan menggunakan algoritma Naïve Bayes akan meningkat dengan dioptimasi menggunakan Algoritma Genetika?

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah menerapkan Algoritma Genetika untuk optimasi algoritma Naïve Bayes serta membandingkan hasil akurasi dengan hasil akurasi algoritma Naïve Bayes.

1.5 Manfa'at Penelitian

Manfaat yang diperoleh dari hasil penelitian ini adalah :

a. Manfaat Praktis

Hasil penelitian ini dapat digunakan sebagai rekomendasi dan masukan bagi Dinas Pertanian dan Kehtanan.

b. Manfaat Teoritis

Hasil penelitian ini dapat memberikan bukti empiris mengenai penerapan algoritma naïve bayes degan menggunakan aloritma genetika dalam memprediksi kebakaran hutan.

1.6 Ruang Lingkup Penelitian

Kasus yang diangkat dalam penelitian ini dibatasi pada komparasi penerapan metode algoritma naïve baye yang akan diterapkan pada kasus kebakaran hutan wilayah Timur Laut Portugal. Data yang digunakan adalah data hasil pengukuran terhadap 517 data. Ada 14 *attribut* yang digunakan untuk memprediksi kebakaran hutan atribut tersebut terdiri dari 13 atribut input dan 1 atribut sebagai atribut output. 14 variabel (atribut), tersebut adalah: x (*Spatia Coodinate within the Montesinho park map:1-9*), y (*Spatia Coodinate within the Montesinho park map:2-9*), *month*, *day*, FFMC, DMC, DC, ISI, *temp*, RH, *wind*, *rain*, kelas. Sedangkan keluaran yang dihasilkan adalah variabel *output* yang bernilai 0 dan 1, 0 untuk kebakaran kecil dan 1 untuk kebakaran besar.

1.7 Sistematika Penulisan

Sistematika penulisan penelitian ini disusun dalam 5 (lima) bab, yang terdiri dari :

BAB 1. PENDAHULUAN

Bab ini terdiri dari beberapa sub bab, antara lain : latar belakang penulisan, masalah penelitian, tujuan dan manfaat penelitian dan sistematika penulisan. Di bab ini juga dijelaskan penelitian terdahulu serta ruang lingkup penelitian yang akan dibuat.

BAB 2. LANDASAN TEORI/KERANGKA PEMIKIRAN

Bab ini berisi tentang obyek penelitian, tinjauan studi, kerangka pemikiran yang melandasi penelitian ini dan hipotesis. Di bab ini juga membahas tools apa saja yang digunakan untuk menyelesaikan penelitian serta bagaimana hasil penelitian itu disampaikan.

BAB 3. METODE PENELITIAN

Bab ini membahas tentang desain penelitian yang terdiri dari jenis penelitian yang dilakukan dan metode pengumpulan data, serta eksperimen yang dilakukan. Di bab ini juga membahas tentang tahapan-tahapan yang akan digunakan dalam penelitian.

BAB 4. HASIL PENELITIAN DAN PEMBAHASAN

Bab ini berisi hasil penelitian, pembahasan dan implikasi penelitian. Di bab ini dijelaskan secara rinci perhitungan manual menggunakan naïve bayes dan perhitungan penyeleksian atribut dengan menggunakan algoritma genetika serta ditampilkan hasil pengujian, serta prototype GUI yang dihasilkan dari metode yang digunakan.

BAB 5. PENUTUP

Bab ini mencakup kesimpulan yang dibuat berdasarkan pembahasan bab-bab sebelumnya, hasil dari algoritma yang digunakan serta kekurangan-kekurangan yang terdapat didalam penelitian sebagai evaluasi penelitian dan saran-saran untuk kepentingan penelitian selanjutnya.

BAB II

LANDASAN TEORI

2.1 Tinjauan Pustaka

Untuk kepentingan penelitian, maka dalam penulisan tesis ini penulis melakukan tinjauan dengan menggunakan buku dan jurnal yang berhubungan dengan tema yang dipilih. Secara lebih detail tinjauan dalam penulisan tesis ini dapat dijelaskan sebagai berikut:

2.1.1 Data Mining

Data mining merupakan perpaduan dari ilmu statistik, kecerdasan buatan (sitem pakar) dan penelitian dalam bidang database, untuk itu diperlukan penyaringan melalui sejumlah besar material data atau melakukan penyelidikan dengan cerdas tentang keberadaan suatu data yang memiliki nilai Daryl Pregibons (Gorunescu, 2011). Data mining juga dapat didefinisikan sebagai sebuah proses untuk menemukan pola data (Witten, 2011).

Knowledge discovery from data (KDD) juga merupakan bagian dari proses data mining, dimana dalam proses penjelajahan pengetahuan dimulai dari beberapa database dengan melakukan proses cleaning dan integration sehingga menghasilkan data warehouse. Selanjutnya melakukan proses *selection* dan transformation kemudian sebut sebagai data mining untuk menemukan pola dan mendapatkan pengetahuan dari data(Han, 2006)

Secara skematis, Gourunescu dalam Widodo(2013) membagi langkah proses pelaksanaan *data mining* dalam tiga aktivitas yaitu:

1. Eksplorasi Data, terdiri dari aktivitas pembersihan data transformasi data, pengurangan dimensi, pemilihan ciri dan lain-lain.
2. Membuat Metode dan Pengujian Vaidasi Model, merupakan pemilihan terhadap model-model yang sudah dikembangkan yang cocok dengan kasus yang dihadapi. Dengan kata lain, dilakukan pemilihan model secara kompetitif.
3. Penerapan model dengan data baru untuk menghasilkan perkiraan dari kasus yang ada. Tahap ini merupakan tahap yang menentukan apakah model yang telah dibangun dapat menjawab permasalahan yang dihadapi.

Menurut Han(2006) data mining dapat dikelompokkan berdasarkan tugas dan fungsi yang dijalankannya, yang terdiri dari enam bagian, yaitu:

1. *Deskripsi*

Deskripsi merupakan tahapan dimana mencari cara untuk menggambarkan pola (*pattern*) dan trend yang terdapat dalam data. Sebagai contoh yaitu, seorang pengumpul suara mengungkap bukti bahwa mereka yang diberhentikan dari jabatannya saat ini, akan kurang mendukung dalam pemilihan presiden. Tahapan *deskripsi* ini bisa dilakukan dengan *exploratory data analysis*, yaitu metode grafik untuk menelusuri data dalam mencari pola dan *trend*.

2. *Estimasi*

Fungsi *Estimasi* dalam data mining memiliki kesamaan dengan klasifikasi, akan tetapi variabel sasaran yang dimilikinya adalah *numerik*. Selanjutnya model dirancang dan dibuat menggunakan record yang lengkap dan juga ada variabel targetnya. Kemudian untuk data baru, *estimasi* dari nilai target dibuat berdasarkan nilai prediksi. Algoritma data mining yang termasuk kedalam Estimasi data mining adalah *Linear Regression*, *Neural Network*, *Support Vector Machine* dan sebagainya.

3. *Prediksi*

Fungsi *Prediksi* juga memiliki kesamaan dengan fungsi klasifikasi dan estimasi, akan tetapi hasil yang diperoleh adalah untuk memprediksi masa depan (*forecasting*). Fungsi prediksi dapat dicontohkan seperti memprediksi harga saham untuk tiga bulan mendatang, memprediksi harga barang tiga bulan mendatang, memprediksi tingkat partisipasi pemilih pada pemilihan presiden dan memprediksi presentasi kenaikan tingkat angka kematian karena kecelakaan untuk tahun mendatang apabila kecepatan berkendara dinaikkan. Metode dan teknik yang digunakan dalam fungsi klasifikasi dan estimasi dapat juga diterapkan untuk melakukan prediksi (dalam keadaan yang tepat). Algoritma yang dapat menyelesaikan permasalahan prediksi adalah *Linear Regression*, *Neural Network*, *Support Vector Machine* dan sebagainya

4. *Klasifikasi*

Pada klasifikasi, yang menjadi sasaran adalah variabel kategori, misalnya atribut penghasilan, yang bisa dikategorikan menjadi tiga kelas atau kategori yaitu, tinggi, sedang, dan rendah. Model data mining membaca sejumlah besar record, dimana tiap record berisi informasi pada variabel target. Tugas klasifikasi ini cocok untuk metode dan teknik data mining. Algoritma akan mengolah dengan cara membaca data set yang berisi variabel prediktor dan variabel target yang telah diklasifikasikan, yaitu penghasilan. Di sini algoritma (*software*) “mempelajari” kombinasi variabel mana yang berhubungan dengan penghasilan yang mana. Data ini disebut training set. Kemudian algoritma akan melihat ke data baru yang belum termasuk klasifikasi manapun. Berdasarkan klasifikasi pada data set kemudian algoritma akan memasukkan data baru tersebut ke dalam klasifikasi yang mana. Metode-metode telah dikembangkan oleh periset untuk menyelesaikan kasus klasifikasi. Algoritma yang dapat menyelesaikan permasalahan klasifikasi data adalah *Naive Bayes*, *K-Nearest Neighbor*, *C4.5*, *ID3*, *CART*, *Linear Discriminant Analysis*, *Logistic Regression* dan sebagainya.

5. *Clustering*

Clustering mengacu pada pengelompokkan record-record, observasi, atau kasus-kasus ke dalam kelas-kelas dari objek yang mirip. Pada clustering tidak ada variabel sasaran. Sebuah cluster adalah koleksi record yang mirip satu sama lain, dan tidak mirip dengan record pada cluster. Tidak seperti klasifikasi, pada clustering tidak ada variabel target. Clustering tidak mengklasifikasi, mengestimasi atau memprediksi tetapi mencari untuk mensegmentasi seluruh data set ke subgroup yang relatif sejenis atau cluster, dimana kemiripan record di dalam cluster dimaksimalkan dan kemiripan dengan *record* di luar *cluster* diminimalkan. Berikut adalah algoritma yang dapat digunakan untuk *data mining clustering* *K-Means*, *K-Medoids*, *Self-Organizing Map (SOM)*, *Fuzzy C-Means* dan sebagainya

6. *Asosiasi*

Tugas asosiasi untuk data mining adalah kegiatan untuk mencari atribut yang “go together.” Dalam dunia bisnis, asosiasi dikenal sebagai *affinity analysis* atau *market basket analysis*, tugas asosiasi adalah membuka rules untuk pengukuran hubungan antara dua atribut atau lebih. Untuk menemukan

association rules, bisa dilakukan dengan algoritma *apriori* dan algoritma GRI (*Generalized Rule Induction*). Berikut adalah algoritma yang dapat digunakan untuk penyelesaian *asosiasi* dalam *data mining* *FP-Growth*, *A Priori* dan sebagainya

2.1.2 Algoritma *Naïve Bayes*.

Algoritma Naïve Bayes merupakan suatu bentuk klasifikasi data dengan menggunakan metode *probabilitas* dan *statistik*. Metode ini pertama kali dikenalkan oleh ilmuwan Inggris Thomas Bayes, yaitu digunakan untuk memprediksi peluang yang terjadi di masa depan berdasarkan pengalaman di masa sebelumnya sehingga dikenal sebagai *teorema Bayes*.

Metode *Teorema bayes* kemudian dikombinasikan dengan *naive* yang diasumsikan dengan kondisi antar atribut yang saling bebas. *Algoritma Naive Bayes* dapat diartikan sebagai sebuah metode yang tidak memiliki aturan, *Naive Bayes* menggunakan cabang matematika yang dikenal dengan teori probabilitas untuk mencari peluang terbesar dari kemungkinan klasifikasi, dengan cara melihat frekuensi tiap klasifikasi pada data training. *Naive Bayes* juga termasuk metode klasifikasi yang sangat populer dan masuk dalam sepuluh algoritma terbaik dalam data mining, algoritma ini juga dikenal dengan nama *Idiot's Bayes*, *Simple Bayes*, dan *Independence Bayes* (Bramer, 2007). *Klasifikasi bayesian* memiliki kemampuan klasifikasi serupa dengan *decision tree* dan *neural network* (Kusrini & Luthfi, 2009). Klasifikasi *Naive Bayes* adalah pengklasifikasian statistik yang dapat digunakan untuk memprediksi probabilitas keanggotaan suatu class.

Bayes rule digunakan untuk menghitung probabilitas suatu class. *Algoritma Naive Bayes* memberikan suatu cara mengkombinasikan peluang terdahulu dengan syarat kemungkinan menjadi sebuah formula yang dapat digunakan untuk menghitung peluang dari tiap kemungkinan yang terjadi.

Berikut adalah bentuk umum dari *teorema bayes*:

$$P(H/X) = \frac{p(X|H)P(H)}{P(X)}$$

(2.1)

Keterangan:

X = Data dengan *class* yang belum diketahui.

H = *Hipotesis* data X merupakan suatu *class spesifik*.

$P(H|X)$ = *Probabilitas hipotesis* H berdasarkan kondisi X (*posteriori probability*).

$P(H)$ = *Probabilitas Hipotesis* H (*prior probability*).

$P(X|H)$ = *Probabilitas* X berdasar kondisi pada *Hipotesis* H

$P(X)$ = *Probabilitas* dari X .

Metode algoritma Naïve bayes merupakan penyederhanaan *metode bayes*. Untuk mempermudah pemahaman, maka *Teorema Bayes* disederhanakan menjadi:

$$P(H|X) = P(X|H) P(X) \quad (2.2)$$

Metode Bayes rule digunakan dan diterapkan untuk melakukan penghitungan terhadap *posterior* dan *probabilitas* dari data sebelumnya. Dalam analisis *bayesian*, fungsi klasifikasi akhir dihasilkan dengan menggabungkan kedua sumber informasi (*prior dan posterior*) untuk menghasilkan probabilitas menggunakan aturan *bayes*.

2.1.3 *Fitur Selection*

Feature selection adalah sebuah proses yang bisa digunakan pada *machine learning* dimana sekumpulan dari *features* yang dimiliki data digunakan untuk pembelajaran algoritma (Kusuma, 2003). *Subset* yang baik memiliki sedikitnya dimensi angka yang paling banyak berkontribusi untuk akurasi dan nantinya akan dibuang sisa dari dimensi yang tidak berkepentingan, ini merupakan langkah penting dalam tahap *preprocessing*.

Forward selection dimulai tanpa variabel dan menambahkan mereka satu persatu, pada setiap langkah ditambahkan variable yang menurunkan *error* paling banyak, sampai semua *error* dihilangkan(Kusuma, 2003)

Backward selection dimulai dengan semua variabel dan membuangnya satu persatu, pada setiap langkah membuang variable yang memiliki error paling banyak(Kusuma, 2003).

2.1.4 Algoritma Genetika

Optimasi adalah proses menyelesaikan suatu masalah tertentu supaya berada pada kondisi yang paling menguntungkan dari suatu sudut pandang(Zukhri,2014). Masalah yang harus diselesaikan berkaitan erat dengan data-data yang dapat dinyatakan dalam satu atau beberapa variabel. Pengertian menguntungkan, biasanya berhubungan dengan pencarian nilai minimum atau pencarian nilai maksimum, bergantung pada sudut pandang yang digunakan.

Algoritma genetika (AG) diperkenalkan pertama kali oleh John Holland (1975) dari Universitas Michigan, John Holland mengatakan bahwa setiap masalah yang berbentuk adaptasi(alami maupun buatan) dapat diformulasikan ke dalam terminologi genetika (Suyanto,2007). Algoritma genetika merupakan suatu algoritma pencarian berdasarkan pada mekanisme seleksi alam dan genetika alam. Algoritma genetika dimulai dengan sekumpulan solusi awal(individu) yang disebut populasi. Satu hal yang sangat penting adalah bahwa satu individu menyatakan satu solusi. Populasi awal akan berevolusi menjadi populasi baru melalui serangkaian iterasi (generasi). Pada akhir iterasi, algoritma genetika mengembalikan satu anggota populasi yang terbaik sebagai solusi untuk masalah yang dihadapi. Pada setiap iterasi, proses evolusi yang terjadi adalah sebahai berikut (Anita,2006):

1. Dua individu dipilih sebagai orang tua (*parent*) berdasarkan mekanisme tertentu. Kedua parent ini kemudian dikawinkan melalui operator crossover (kawin silang) untuk menghasilkan dua individu anak atau offspring.
2. Dengan probabilitas tertentu, dua individu anak ini mungkin mengalami perubahan gen melalui operator mutation.
3. Suatu skema penggantian (*replacement scheme*) tertentu diterapkan sehingga menghasilkan populasi baru.
4. Proses ini terus berulang sampai kondisi berhenti (*stopping condition*) tertentu. Kondisi berhenti bisa berupa jumlah iterasi tertentu, waktu tertentu, atau ketika variansi individu-individu dalam populasi tersebut sudah lebih kecil dari suatu nilai tertentu yang diinginkan.

Berikut ini contoh aplikasi algoritma genetika yang digunakan untuk menyelesaikan masalah kombinasi. Misalkan ada persamaan :

$$\textbf{“a+3b+2c=30”}$$

Untuk menyelesaikan permasalahan persamaan diatas dapat dilakukan dengan algoritma genetika, berikut langkah-langkah penyelesaiannya:

1. Langkah 1 adalah menentukan populasi awal

C1 :[15_2_7]

C2 :[20_3_1]

C3 :[10_5_8]

C4 :[24_8_9]

C5 :[17_4_6]

2. Langkah 2 adalah evaluasi nilai fitness

Dengan rumus yang sebelumnya telah ditentukan yaitu $a+3b+2c=30$, maka akan menghasilkan nilai *fitness* pada setiap *chromosome*,

$$\begin{aligned}\text{Fitness C1} &= 1/(1 + |(a+3b+2c) - 30|) \\ &= 1/(1 + |((15)+(3*2)+(2*7))-30|) \\ &= 1/(1 + 8) \\ &= 1/9 \\ &= 0,111\end{aligned}$$

$$\begin{aligned}\text{Fitness C2} &= 1/(1 + |(a+3b+2c) - 30|) \\ &= 1/(1 + |((20)+(3*3)+(2*1))-30|) \\ &= 1/(1 + 1) \\ &= 1/2 \\ &= 0,500\end{aligned}$$

$$\begin{aligned}\text{Fitness C3} &= 1/(1 + |(a+3b+2c) - 30|) \\ &= 1/(1 + |((10)+(3*5)+(2*8))-30|) \\ &= 1/(1 + 11) \\ &= 1/2 \\ &= 0,083\end{aligned}$$

$$\begin{aligned}\text{Fitness C4} &= 1/(1 + |(a+3b+2c) - 30|) \\ &= 1/(1 + |((24)+(3*8)+(2*9))-30|) \\ &= 1/(1 + 36)\end{aligned}$$

$$= 1/36$$

$$= 0,027$$

Fitness C5

$$= 1/(1 + |(a+3b+2c) - 30|)$$

$$= 1/(1 + |((17)+(3*4)+(2*6)-30|)$$

$$= 1/(1 + 10)$$

$$= 1/10$$

$$= 0,100$$

Total nilai fitness adalah $0,111+0,500+0,083+0,027+0,100 = \mathbf{0,821}$

Probabilitas masing-masing kromosom menjadi:

$$P[1] = 0,111/0,821 = 0,135$$

$$P[2] = 0,500/0,821 = 0,609$$

$$P[3] = 0,083/0,821 = 0,101$$

$$P[4] = 0,027/0,821 = 0,032$$

$$P[5] = 0,100/0,821 = 0,121$$

Dari hasil probabilitas tertinggi, dihasilkan bahwa *kromosom 2* mempunyai nilai *fitness* paling tinggi. Maka *kromosom 2* juga mempunyai kesempatan paling besar dalam proses seleksi selanjutnya dengan *Roulette Wheel*.

3. Penentuan *Kromosom* Induk

Untuk proses seleksi digunakan *Roulette Wheel*, untuk itu diperlukan nilai kumulatif probabilitasnya dari setiap kromosom, yakni sebagai berikut:

$$C1 = 0,135 \qquad \qquad \qquad = 0,135$$

$$C2 = 0,135 + 0,609 \qquad \qquad \qquad = 0,744$$

$$C3 = 0,135 + 0,609 + 0,101 \qquad \qquad \qquad = 0,845$$

$$C4 = 0,135 + 0,609 + 0,101 + 0,032 \qquad \qquad \qquad = 0,877$$

$$C5 = 0,135 + 0,609 + 0,101 + 0,032 + 0,121 \qquad \qquad \qquad = 1$$

Langkah selanjutnya adalah dengan menggunakan bilangan acak R antara 0 sampai dengan 1, bilangan acak dipilih sesuai dengan jumlah *kromosom*:

$$R[1] = 0,234$$

$$R[2] = 0,451$$

$$R[3] = 0,508$$

$$R[4] = 0,134$$

$R[5] = 0,680$

Memilih kromosom ke x sebagai *parent* dengan syarat $C[x-1] < R < C[x]$. Angka acak $R[1] < \text{nilai kumulatif dari } C2$, sehingga $C2$ nanti akan dilakukan *crossover* dengan $C1$. Hasil seleksi Roullete Wheel pada populasi ini untuk *crossover* menjadi:

$C1 \text{ Menjadi } C2 = [20_3_1]$

$C2 \text{ Menjadi } C2 = [20_3_1]$

$C3 \text{ Menjadi } C3 = [10_5_8]$

$C4 \text{ Menjadi } C4 = [24_8_9]$

$C5 \text{ Menjadi } C5 = [17_4_6]$

4. Perkawinan silang atau Crossover

Dalam *crossover* kita menentukan Probability (pr), yaitu sebesar 0.5 atau 50%. Hanya kromosom yang nilai R lebih kecil dari 0.5 yang akan bermutasi. Maka Kromosom ke y akan dipilih menjadi induk jika $R[y] < pr$, dari bilangan acak R diatas maka yang dijadikan parent adalah $C1$, $C2$, dan $C4$. Sedangkan $C3$ dan $C5 > 0.5$, sehingga tidak dilakukan seleksi. Selanjutnya setelah melakukan pemilihan parent, dilanjutkan menentukan kromosom yang akan dilakukan perkawinan silang dengan pengambilan sejumlah atribut 1-3. Dalam hal ini posisi cut-point (cp) dipilih menggunakan bilangan acak dari 1-3 sesuai banyaknya crossover yang terjadi. Misalnya didapatkan posisi crossover adalah 3, maka kromosom parent akan dipotong mulai gen ke 3 kemudian potongan gen tersebut saling ditukarkan antar parent.

$C1 \times C2$

$cp(C1) = 2$

$cp(C2) = 3$

$cp(C4) = 1$

nilai Offspring[1] = $C1 \times C2$ dengan $cp(C1)$

$[20_3_1] \times [20_3_1]$

$[20_3_1]$

nilai Offspring[2] = $C2 \times C2$ dengan $cp(C2)$

$[20_3_1] \times [20_3_1]$

$[20_3_1]$

$$\begin{aligned}
\text{nilai Offspring}[4] &= C4 \times C4 \text{ dengan cp}(C4) \\
&= [24_8_9] \times [24_8_9] \\
&= [24_8_9]
\end{aligned}$$

Sehingga Populasi baru yang dihasilkan dari *crossover* adalah:

$$C1 = [20_3_1]$$

$$C2 = [20_3_1]$$

$$C3 = [10_5_8]$$

$$C4 = [24_8_9]$$

$$C5 = [17_4_6]$$

5. Mutasi Kromosom

Jumlah kromosom yang mengalami mutasi dalam satu populasi ditentukan oleh persentase p mutation. Proses mutasi dilakukan dengan cara mengganti satu gen yang terpilih secara acak dengan suatu nilai baru yang didapat secara acak.

$$\begin{aligned}
\text{Total gen} &= (\text{gen dalam kromosom}) * \text{jumlah kromosom} \\
&= 3 * 5 \\
&= 15
\end{aligned}$$

Tentukan posisi gen yang akan mengalami mutasi dengan menggunakan bilangan acak antara 1 sampai dengan total gen, yaitu antara 1 sampai 15. Misalkan pm kita tentukan 10% maka jumlah gen yang mengalami mutasi adalah 10% dari 15 yaitu 1,5 atau 1 gen.

Kemudian gunakan bilangan acak dari total gen misalkan yang terpilih adalah posisi gen 6 yang akan mengalami mutasi. Dengan demikian yang akan mengalami mutasi adalah kromosome ke-2 gen nomor 3. Maka nilai gen pada posisi tersebut akan diganti dengan bilangan acak 0-30. Misalkan bilangan acak yang digunakan adalah 3, maka kromosom ke-2 berubah menjadi [20_3_3] Populasi pada generasi pertama menjadi:

$$C1 = [20_3_1]$$

$$C2 = [20_3_3]$$

$$C3 = [10_5_8]$$

$$C4 = [24_8_9]$$

$$C5 = [17_4_6]$$

Kromosom ke-2 kemudian di uji pada rumus $a+3b+2c=30$, agar menjadi kromosom yang ingin dicapai. $(20)+(3*5)+2*1 < 30$, maka populasi ini belum memiliki kromosom yang ingin dicapai. Kromosom-kromosom pada populasi ini akan mengalami proses yang sama seperti generasi sebelumnya yaitu proses evaluasi, seleksi, *crossover* dan mutasi yang kemudian akan menghasilkan kromosom-kromosom baru untuk generasi yang selanjutnya. Proses ini akan berulang sampai sejumlah generasi yang telah ditetapkan sebelumnya.

2.1.5 Kebakaran Hutan

Kebakaran hutan merupakan salah satu jenis gangguan bagi ekosistem hutan. Semakin banyak bukti menunjukkan bahwa perubahan iklim global mempengaruhi terjadinya kebakaran hutan (William et al, 2001).

Kebakaran hutan merupakan salah satu masalah lingkungan yang utama karena dampak dari kebakaran hutan adalah menciptakan melemahnya perekonomian suatu negara dan merusak ekosistem serta membahayakan manusia. Area kebakaran kecil adalah kebakaran dibawah 1 hektar yaitu $1\text{ha}/100=100\text{ m}^2$ sedangkan untuk kebakaran besar adalah kebakaran diatas 1 hektar (Cortez dan Moraiz, 2007).

Kebakaran hutan yang kecil sekalipun dapat menyebabkan rusaknya cagar alam dimana disana merupakan lahan yang dilindungi dan terdapat banyak spesies yang berbeda yang berkembang karena ekologi yang seimbang (Iyer et al, 2011).

Penelitian sebelumnya menunjukkan bahwa ada hubungannya kondisi meteorologi dengan terjadinya kebakaran hutan hal ini diyakini karena munculnya api sebagian besar dapat disebabkan dari variable meteorologi seperti suhu, kelembaban, kecepatan angin dan curah hujan.

Deteksi kebakaran hutan yang cepat adalah kunci utama dalam mencegah terjadinya kebakaran hutan. Salah satu alternatif adalah dengan menggunakan alat otomatis berdasarkan sensor lokal, seperti yang dimiliki oleh badan meteorologi. Alat tersebut dapat berupa satelit, *scanner inframerah*/asap dan sensor lokal.

2.1.6 Variable yang mempengaruhi terjadinya kebakaran hutan

FWI (*Fire Weather Index*) adalah sistem deteksi yang memberikan rating terhadap besar kecilnya kebakaran hutan yang dimiliki oleh Kanada. Dalam sistem

FWI ini terdapat enam komponen yang digunakan untuk memprediksi kebakaran hutan. Enam komponen tersebut adalah:

1. *FFMC (Fine Fuel Moisture Code)*

FFMC akan menunjukan seberapa besar kadar air, sampah yang ada di permukaan tanah yang akan mempengaruhi terjadinya api dan menunjukan seberapa besar kebakaran akan menyebar.

2. *DMC (Duff Moisture Code)* dan *DC (Drought Code)*.

DMC (Duff Moisture Code) dan *DC (Drought Code)* Mewakili kadar air yang dimiliki oleh lapisan organik, kadar air tersebut dangkal atau dalam serta mempengaruhi intensitas api.

3. *ISI (Initial Spread Index)*

ISI (Initial Spread Index) adalah skor yang berkorelasi dengan kecepatan penyebaran kebakaran sementara.


4. *BUI (Buildup Index)*

BUI (Buildup Index) adalah index dari jumlah bahan bakar yang tersedia.

5. *FWI (Fire Weather Index)*

FWI (Fire Weather Index) adalah merupakan indikator intensitas kebakaran yang melibatkan dua komponen sebelumnya. Dua komponen sebelumnya adalah *DMC (Duff Moisture Code)* dan *DC (Drought Code)*.

Meskipun skala yang berbeda digunakan untuk masing-masing unsur FWI, nilai-nilai yang tinggi menunjukkan kondisi pembakaran yang lebih parah. Kode kelembaban bahan bakar memerlukan memori (jeda waktu) dari kondisi cuaca terakhir: 16 jam untuk FFMI, 12 hari untuk DMC dan 52 hari untuk DC.



Sumber: <http://cwfis.cfs.nrcan.gc.ca/>

Gambar 2.1 Fire Weather Index Struktur

Selain menggunakan variabel yang di dapatkan dari sistem FWI (*Fire Weather Index*) dalam penelitian ini juga menggunakan variabel meteorologi seperti Suhu, Kelembaban, kecepatan angin dan curah hujan sedangkan variabel output adalah variabel kelas.

2.1.7 Evaluasi Penelitian

Evaluasi adalah kunci ketika membuat aplikasi berbasis *data mining*. Ada berbagai macam cara dalam melakukan evaluasi. Jika kita memiliki data yang kita gunakan dalam proses pelatihan, maka tidak serta merta menjadikan data tersebut sebagai indikator keberhasilan aplikasi yang kita buat. Oleh karena itu kita membutuhkan metode untuk tertentu guna memprediksi performa berdasarkan eksperimen untuk berbagai macam data selain data *training* (Widodo, 2013).

Dalam penelitian ini evaluasi penelitian dilakukan dengan menggunakan *Confussion matrix* dan Kurva ROC.

A. *Confussion matrix*

Confussion matrix adalah sebuah metode untuk melakukan evaluasi dengan menggunakan tabel matrix. Pada tabel 2 dapat dilihat bahwa jika *dataset* terdiri dari dua *class*, dimana *class* yang satu dianggap sebagai *class positif* dan

class yang lainnya dianggap sebagai *class negatif* (Bramer, 2007). Evaluasi dengan menggunakan fungsi *confusion matrix* akan menghasilkan nilai *accuracy*, *precision*, dan *recall*.

Nilai *accuracy* adalah *presentase* dari jumlah *record data* yang diklasifikasikan secara baik dan benar dengan menggunakan sebuah algoritma dan dapat membuat klasifikasi setelah dilakukan pengujian pada hasil klasifikasi tersebut (Han & Kamber, 2006). Nilai *precision* atau yang juga dikenal dengan nama *confidence value* merupakan *proporsi* dari jumlah kasus yang diprediksi mendapatkan hasil positif dimana nilainya juga positif pada data yang sebenarnya. Sedangkan nilai dari *Recall* atau *sensitivity value* merupakan *proporsi* dari jumlah kasus yang bernilai positif yang sebenarnya dan diprediksi positif secara benar. (Powers, 2011).

Tabel 2.1 Model Confussion Matrix.

Correct Classification	Classified as	
	Positive	Negative
<i>Positive</i>	<i>True Positives</i>	<i>False Negatives</i>
<i>Negative</i>	<i>False Negatives</i>	<i>True Negatives</i>

Model *Confussion Matrix* pada tabel 2 diatas, dapat dijelaskan sebagai berikut, dimana *True Positive* merupakan jumlah *record positive* yang diklasifikasikan sebagai *positive*, *false positive* adalah jumlah *record negative* yang diklasifikasikan sebagai *positive*, *false negative* adalah jumlah *record positive* yang diklasifikasikan sebagai *negative*, *true negative* adalah jumlah *record negative* yang diklasifikasikan sebagai *negative*, kemudian masukkan data uji. Setelah data uji dimasukkan ke dalam *Confussion Matrix*, hitung nilai-nilai yang telah dimasukkan tersebut untuk dihitung jumlah *sensitivity (recall)*, *Specifity*, *Precision*, dan *Accuracy*. Selanjutnya *Sensitivity* digunakan untuk membandingkan jumlah *t_pos* terhadap jumlah *record* yang *positive* sedangkan *Specifity*, *Precision* adalah jumlah *t_neg* terhadap jumlah *record* yang *negative*. Berikut persamaan dari *confussion matrix*. (Han & Kamber).

$$Sensitivity = \frac{t_{pos}}{pos}$$

$$Specifity = \frac{t_{neg}}{neg}$$

$$Precision = \frac{t_{pos}}{t_{pos} + f_{pos}}$$

$$Accuracy = Sensitivity \frac{pos}{pos+neg} + specificity \frac{neg}{pos+neg} \quad (2.3)$$

Keterangan:

- t_pos : jumlah *true positive*
- t_neg : jumlah *true negative*
- p : jumlah *record positive*
- n : jumlah *tupel negative*
- f_pos : jumlah *false positive*

B. Kurva Receiver Operating Characteristic (ROC).

Fungsi Kurva ROC adalah untuk menunjukkan akurasi dan membandingkan klasifikasi secara visual. ROC mengekspresikan *Confusion Matrix*, ROC adalah grafik dua dimensi dengan *false positives* sebagai garis *horizontal* dan *true positive* sebagai garis *vertical* (Vercellis, 2009).

Dalam masalah klasifikasi menggunakan dua kelas keputusan (*klasifikasi biner*), masing-masing objek dikelompokkan dalam (P, N), yaitu positif dan negatif. Selain itu ada beberapa model klasifikasi (seperti pohon keputusan) menghasilkan *label class diskrit* (hanya menunjukkan class yang diprediksi oleh objek), klasifikasi yang lain seperti *Naïve Baiyes* dan *Neural Network* juga menghasilkan output yang berkesinambungan, dimana ambang batas yang berbeda mungkin diterapkan untuk memprediksi keanggotaan *class*.

Secara teknis *kurva ROC* juga dikenal sebagai grafik ROC, dua dimensi grafik dimana tingkat TP diplot pada sumbu Y dan tingkat FP diplot pada sumbu X (Gorunescu, 2011).

Hasil perhitungan dapat divisualisasikan dengan kurva ROC (*Receiver Operating Characteristic*) atau AUC (*Area Under Curve*). Berikut tingkat nilai diagnosa dari ROC, yaitu: (Gorunescu, 2011).

- a. Akurasi bernilai 0.90 – 1.00 = *Excellent classification*
- b. Akurasi bernilai 0.80 – 0.90 = *Good classification*
- c. Akurasi bernilai 0.70 – 0.80 = *Fair classification*

- d. Akurasi bernilai $0.60 - 0.70 = \text{Poor classification}$
- e. Akurasi bernilai $0.50 - 0.60 = \text{Failure}$

C. SQA (*Software Quality Assurance*)

Metode SQA (*Software Quality Assurance*) digunakan untuk mengukur dan memastikan bahwa perangkat lunak atau aplikasi yang dibuat memiliki standar minimal kualitas, sehingga para pengembang dapat mengetahui kualitas dari perangkat lunak yang dikembangkan. Ada delapan buah kriteria yang dapat digunakan untuk mengukur kualitas dari sebuah perangkat lunak secara kuantitatif, seperti yang terlihat pada tabel 2.2 dibawah ini:

Tabel 2.2 Metric software quality assurance (SQA)

No	Metric	Deskripsi	Bobot
1	<i>Auditability</i>	Memenuhi standar atau tidak	0.125
2	<i>Accuracy</i>	Keakuratan komputasi	0.125
3	<i>Completeness</i>	Kelengkapan	0.125
4	<i>Error tolerance</i>	Toleransi terhadap kesalahan	0.125
5	<i>Excecution efficiency</i>	Kinerja eksekusi	0.125
6	<i>Operability</i>	Kemudahan untuk dioperasikan	0.125
7	<i>Simplicity</i>	Kemudahan untuk difahami	0.125
8	<i>Training</i>	Kemudahan pembelajaran fasilitas	0.125

Berikut adalah skala pengukuran kualitas perangkat lunak secara kualitatif dengan menggunakan metode penilaian skala *likert*, dibawah ini adalah tabel kriteria skala penilaian:

Tabel 2.3 Kriteria Skala Penilaian

Skala	Keterangan	Bobot	Nilai Jawaban
SO	Sangat Optimal	5	81-100
O	Optimal	4	61-80
CO	Cukup Optimal	3	41-60
TO	Tidak Optimal	2	21-40
STO	Sangat Tidak Optimal	1	0-20

Sumber: Sugiyono (2012)

2.2 Tinjauan Studi

Pada sub bab ini akan dibahas tentang tinjauan studi terdahulu yang pernah dilakukan oleh para peneliti, diantaranya sebagai berikut:

Penelitian terdahulu tentang prediksi kebakaran hutan telah banyak dilakukan, seperti penelitian yang dilakukan oleh beberapa peneliti, diantaranya adalah: penelitian yang dilakukan oleh Paulo Cortez dan Anibal Moraiz yang berjudul *A Data Mining Approach to Predict Forest Fires Using Meteorological Data* menggunakan *ANN, SVM, MR, RF, Naïve, dan decision tree*, yang membahas tentang komparasi 6 metode kecerdasan buatan *ANN, SVM, MR, RF, Naïve, dan decision tree*. Dari penelitian ini menunjukkan SVM lebih baik dalam memprediksi kebakaran hutan dalam skala kecil dan akurasi prediksinya 64,7 % (Cortez and Moraiz, 2007).

Penelitian selanjutnya dilakukan oleh Vasanth Iyer, S. Sitharama Iyengar, N. Paramesh, dan Garmiela Rhama Murty dengan judul penelitian *Machine Learning and Data Mining Algorithm for Predicting Accidental Small Forest Fires*, menggunakan Naïve Bayes dan *J48 Three Classifiers*. Yang membahas komparasi dua algoritma Naïve Bayes dan *J48 Three Classifiers*. Akurasi yang didapat dari prediksi kebakaran hutan kecil (Accidental Fair + Small Fair) *J48 Three Classifiers* memiliki akurasi 80% sedangkan Naïve Bayes 61 %. Sedangkan prediksi untuk keseluruhan kategori kebakaran untuk *J48 Three Classifiers* 72,1 % sedangkan Naïve Bayes 51, 64% dilihat dari hasil akurasi maka akurasi *J48 Three Classifiers* lebih baik dari pada Naïve Bayes.

Tabel 2.4. State of the art research Prediks Kebakaran Hutan


Penelitian	Tahun	Masalah	Metode	Hasil
Cortez dan Anibal Moraiz	2007	Akurasi prediksi yang lebih rendah untuk memprediksi kebakaran hutan yang	<i>ANN, SVM, MR, RF, Naïve, dan decision tree</i>	Hasil prediksi menunjukan bahwa SVM (<i>Support Vector Machines</i>) menunjukan

Penelitian	Tahun	Masalah	Metode	Hasil
		besar		akurasi tertinggi yaitu 64,7 %
Vasanth Iyer, S. Sitharama Iyengar, N. Paramesh, dan Garmiela Rhama Murty	2011	Kebakaran besar tidak berkorelasi, atribut yang memiliki nilai sama menciptakan kesalahan <i>over-fitting error during Learning</i>	J48 <i>Three Classifiers</i> dan Naïve Bayes	Hasil prediksi menunjukan bahwa J48 <i>Three Classifiers</i> lebih besar tingkat akurasinya yaitu 80%
Yong Poh Yu , Rosli Omar , Rhett D. Harrison , Mohan Kumar Sammathuria and Abdul Rahim Nik	2011	Kebakaran hutan tidak di klasifikasikan	Back-propagation network	Nilai akurasi yang di dapatkan adalah 93%

Perbedaan penelitian ini dengan penelitian sebelumnya adalah:

1. penelitian ini hanya membagi kedalam 2 kelas data yang ada, yaitu kelas kebakaran kecil dan kelas kebakaran besar.
2. Penelitian ini menggunakan algoritma Naïve Bayes yang dioptimasi dengan menggunakan algoritma genetika sebagai fitur seleksinya.
3. Penelitian ini membandingkan nilai akurasi dari algoritma Naïve Bayes dengan nilai akurasi algoritma Naïve Bayes yang telah dioptimasi dengan Algoritma Genetika.

2.3 Kerangka Pemikiran



Gambar 2.2 Kerangka Pemikiran

Pada gambar 2.2 diatas dapat dijelaskan kerangka pemikiran dari penelitian, yang dimulai dengan tahapan pertama yaitu, penentuan masalah berdasarkan masalah yang telah diprediksi sebelumnya yakni prediksi tentang seberapa besar tingkat akurasi algoritma *Naïve Bayes* dalam memprediksi kebakaran hutan, selanjutnya untuk membuktikan, maka digunakan metode pengukuran prediksi Algoritma *Naïve Bayes* dan agar hasilnya lebih optimal maka di optimasi dengan Algoritma Genetika.. Untuk mengevaluasi penelitian maka digunakan alat bantu untuk mengukur data eksperimen dengan menggunakan *software Rapid Miner 5.3*, data penelitian diambil dari hasil UCI Repository. Evaluasi dari pengujian dan validasi menggunakan *confusion matrix* dan hasil dalam bentuk kurva menggunakan kurva *ROC*. Melakukan evaluasi dengan menggunakan data tersebut kemudian diterapkan kedalam aplikasi perangkat lunak. Diharapkan hasil dari penelitian ini algoritma *Naïve Bayes* yang dioptimasi dengan Algoritma Genetika dapat memprediksi keakuratan prediksi kebakaran hutan dengan akurasi yang tinggi.

2.4 Prototype

Pembuatan *prototype* dilakukan dalam penelitian ini, *prototype* dibuat menggunakan visual basic 6.0, yang merupakan bahasa pemrograman yang paling mudah untuk pembuatan aplikasi. *Prototype* dibuat untuk evaluasi hasil prediksi.

Menurut Suryana (2009:1) *Visual Basic* merupakan sebuah aplikasi yang digunakan untuk pengembangan dengan memanfaatkan keistimewaan konsep-konsep antar muka grafis dalam microsoft windows.

2.5 Hipotesa

Hipotesa yang didapatkan dalam prediksi ini adalah diduga dengan menggunakan algoritma genetika sebagai *fiture selection* untuk mengoptimalkan hasil akurasi algoritma naïve bayes, akan meningkat tingkat akurasinya.

BAB III

METODOLOGI PENELITIAN

3.1 Jenis Penelitian

Metode penelitian adalah ilmu yang membahas metode ilmiah dalam mencari, mengembangkan, dan menguji kebenaran suatu ilmu pengetahuan

Pada umumnya para peneliti menggunakan beberapa metode penelitian yang berbeda, akan tetapi yang sering digunakan terdiri dari empat metode, yaitu: metode eksperimen, metode tindakan penelitian, metode studi kasus dan metode survei (Dawson, 2009).

Jenis penelitian yang digunakan dalam penelitian ini adalah model penelitian eksperimen. Model eksperimen merupakan metode penelitian yang digunakan untuk mencari pengaruh perilaku tertentu (Sugiyono, 2010). Penelitian ini bertujuan untuk melakukan perbandingan dan evaluasi pada algoritma klasifikasi data mining.

Penelitian eksperimen ini menggunakan penerapan algoritma Naïve Bayes berbasis Algoritma Genetika untuk meningkatkan hasil akurasi prediksi jenis kebakaran hutan.

Beberapa langkah yang harus dilakukan dalam proses pelaksanaan penelitian diantaranya adalah sebagai berikut:

1. Pengumpulan data

Pada tahap ini ditentukan data yang akan diproses. Mencari data yang tersedia, memperoleh data tambahan yang dibutuhkan, mengintegrasikan semua data kedalam data set, termasuk variabel yang diperlukan dalam proses.

2. Pengolahan data awal

Ditahap ini dilakukan penyeleksian data, data dibersihkan dan ditransformasikan ke bentuk yang diinginkan sehingga dapat dilakukan persiapan dalam pembuatan model.

3. Metode yang diusulkan

Pada tahap ini data dianalisis, dikelompokkan variabel mana yang berhubungan dengan satu sama lainnya. Setelah data dianalisis lalu diterapkan model-model yang sesuai dengan jenis data.


4. Eksperimen dan pengujian metode

Pada tahap ini model yang diusulkan akan diuji untuk melihat hasil berupa rule yang akan dimanfaatkan dalam pengambilan keputusan.

5. Evaluasi dan validasi

Pada tahap ini dilakukan evaluasi terhadap model yang ditetapkan untuk mengetahui tingkat keakurasian model.

Berikut gambar langkah-langkah dalam tahapan penelitian:



Gambar 3.1 Tahapan Penelitian

3.2 Pengumpulan Data

Untuk mendapatkan data yang berkualitas, maka diperlukan teknik yang baik dan benar. Teknik pengumpulan data merupakan sebuah cara atau teknik yang digunakan untuk mengolah dan menggunakan data (Riduwan,2008).

a. Sumber Data

Metode pengumpulan data untuk mendapatkan sumber data dibagi menjadi dua, yaitu data primer dan data sekunder. Data primer yaitu data yang dikumpulkan pertama kali, dan untuk melihat apa yang sesungguhnya terjadi melalui observasi, interview, kuesioner, dll. Data sekunder adalah data yang telah dikumpulkan dan

dianalisis oleh orang lain baik yang telah dipublikasikan maupun yang belum dipublikasikan, misalnya dari dokumentasi, literatur, buku, jurnal, dan informasi lainnya yang ada hubungannya dengan masalah yang diteliti. Dalam penelitian ini metode pengumpulan data untuk mendapatkan sumber data yang digunakan adalah metode pengumpulan data sekunder. Data utama diperoleh dari *University of California Irvine machine learning data repository* yang dapat diperoleh melalui alamat web <http://archive.ics.uci.edu/ml/>, sedangkan data pendukung didapatkan dari buku, jurnal dan publikasi lainnya.

b. Sampel Penelitian

Sampel dari Penelitian ini adalah data kebakaran hutan di Portugal, data tersebut yang bersifat *public* yang didapatkan dari *University of California Irvine machine learning data repository*.

Table 3.1

Data Kebakaran Hutan Wilayah Timur Laut Portugal (Montensinho Park)

X	Y	Month	day	FFMC	DMC	DC	ISI	Temp	RH	Wind	rain	area	Kelas
3	4	8	2	91	14,6	25,6	12,3	13,7	33	9,4	0	61,13	1
4	3	9	5	84,6	3,2	43,6	3,3	8,2	53	9,4	0	4,62	1
2	4	9	1	93,7	121,7	350,2	18	22,7	40	9,4	0	3,19	1
1	4	9	6	91,2	48,3	97,8	12,5	14,6	26	9,4	0	2,53	1
3	4	8	5	90,1	108	529,8	12,5	21,2	51	8,9	0	0,61	0
6	4	2	2	85,4	25,4	349,7	2,6	5,1	24	8,5	0	24,77	1
7	4	8	6	85,4	25,4	349,7	2,6	4,6	21	8,5	0	22,03	1
3	4	7	1	85,4	25,4	349,7	2,6	4,6	21	8,5	0	17,85	1
2	4	8	1	85,4	25,4	349,7	2,6	4,6	21	8,5	0	10,73	1
2	5	8	7	85,4	25,4	349,7	2,6	4,6	21	8,5	0	9,77	1
5	4	8	7	84,4	27,2	353,5	6,8	4,8	57	8,5	0	8,98	1
6	5	5	6	90,6	50,1	100,4	7,8	15,2	31	8,5	0	1,94	1
4	4	4	5	91	166,9	752,6	7,1	18,5	73	8,5	0	0	0
1	4	9	7	85,2	4,9	15,8	6,3	7,5	46	8	0	24,24	1
2	4	8	7	84	27,8	354,6	5,3	5,1	61	8	0	11,19	1
1	4	9	7	91,6	273,8	819,1	7,7	15,5	72	8	0	1,94	1
1	3	9	1	90,7	80,9	368,3	16,8	14,8	78	8	0	0	0
8	6	8	7	93,4	17,3	28,3	9,9	8,9	35	8	0	0	0
4	4	8	3	95,1	141,3	605,8	17,7	19,4	71	7,6	0	46,7	1
Data Selengkapnya ada di Lampiran I													

3.3 Pengolahan Data Awal

Dalam melakukan penelitian diperlukan data awal yang nantinya akan digunakan dalam penelitian, data awal yang didapat sebanyak 517 data, akan tetapi tidak semua atribut data dapat digunakan dan harus melalui beberapa tahapan pengolahan awal data. Berikut beberapa teknik yang dapat digunakan untuk mendapatkan dataset yang berkualitas tinggi, sehingga dapat diterapkan dalam analisis data mining, diantaranya adalah: (Vercellis, 2009).

a. *Data Validation*

Tahapan *data validation* dilakukan untuk proses mengidentifikasi dan menghapus *anomali dan inkonsistensi* dari data. Anomali dan inkonsistensi data dapat terjadi dikarenakan oleh beberapa masalah, seperti; adanya *missing values* dan juga karena data yang dipakai mengandung nilai-nilai yang salah atau disebut dengan *noise* dan *outlier*.

b. *Data Integration dan data Transformation*

Tahap selanjutnya adalah menerapkan *Data Integration dan Data Transformation* pada beberapa dataset untuk meningkatkan akurasi dan efisiensi dari model pembelajaran algoritma yang digunakan. Data yang digunakan dalam penulisan ini bernilai *kategorikal*. Data tersebut akan ditransformasikan kedalam *software Rapidminer 5.3*.

c. *Data Reduction*

Tahapan terakhir adalah *Data Reduction* yaitu suatu teknik yang digunakan untuk mereduksi ukuran data jika dataset yang digunakan cukup besar yang berguna untuk membuat model pembelajaran algoritma menjadi lebih efisien tanpa mengurangi kualitas dari hasil yang diperoleh.

Ada 14 atribut yang digunakan untuk memprediksi jenis kebakaran hutan atribut tersebut terdiri dari 13 atribut input dan 1 atribut sebagai atribut output. 14 variabel (atribut), tersebut adalah: x (Spatial Coordinate within the Montesinho park map:1-9), y (Spatial Coordinate within the Montesinho park map:2-9), month, day, FFMC, DMC, DC, ISI, temp, RH, wind, rain, area dan kelas. Sedangkan keluaran yang dihasilkan

adalah variabel *output* yang bernilai terjadi 0 untuk tidak kebakaran dan 1 untuk kebakaran.

1. FPMC (*Fine Fuel Moisture Code*)

FFMC akan menunjukkan seberapa besar kadar air, sampah yang ada di permukaan tanah yang akan mempengaruhi terjadinya api dan menunjukkan seberapa besar kebakaran akan menyebar.

2. DMC (*Duff Moisture Code*) dan DC (*Drought Code*).

DMC (*Duff Moisture Code*) dan DC (*Drought Code*) Mewakili kadar air yang dimiliki oleh lapisan organik, kadar air tersebut dangkal atau dalam serta mempengaruhi intensitas api.

3. ISI (*Initial Spread Index*)

ISI (*Initial Spread Index*) adalah skor yang berkorelasi dengan kecepatan penyebaran kebakaran sementara.

4. BUI (*Buildup Index*)

BUI (*Buildup Index*) adalah index dari jumlah bahan bakar yang tersedia.

5. FWI (*Fire Weather Index*)

FWI (*Fire Weather Index*) adalah merupakan indikator intensitas kebakaran yang melibatkan dua komponen sebelumnya. Dua komponen sebelumnya adalah DMC (*Duff Moisture Code*) dan DC (*Drought Code*).

Meskipun skala yang berbeda digunakan untuk masing-masing unsur FWI, nilai-nilai yang tinggi menunjukkan kondisi pembakaran yang lebih parah. Kode kelembaban bahan bakar memerlukan memori (jeda waktu) dari kondisi cuaca terakhir : 16 jam untuk FFMC, 12 hari untuk DMC dan 52 hari untuk DC.


Selain menggunakan variable-variable yang didapatkan dari sistem FWI (*Fire Weather Index*) dalam penelitian ini juga menggunakan variable meteorologi seperti Suhu, Kelembaban, kecepatan angin dan curah hujan sedangkan variable output adalah variable kelas yang bernilai 1 dan 0, 1 untuk kebakaran besar 0 untuk kebakaran kecil.

Tabel 3.2 Tabel Atribut yang digunakan (Diolah dari berbagai sumber sesuai kondisi).

No	Atribut	Nilai
1	X	<i>Spatia Coodinate within the Montesinho park map:1-9</i>
2	Y	<i>Spatia Coodinate within the Montesinho park map:2-9</i>
3	<i>Month</i>	Bulan yang terdapat dalam data yang akan diolah adalah 1 s/d 12
4	<i>Day</i>	Hari yang terdapat dalam data yang akan diolah adalah 1 s/d 7
5	FFMC	FFMC adalah <i>attribut</i> yang dihasilkan dari sistem FWI yang mengukur kadar air, sampah yang ada dipermukaan tanah dikelompokkan menjadi 3 Kondisi yaitu <80, <90 dan >=90
6	DCM	DMC adalah <i>attribut</i> yang dihasilkan dari sistem FWI yang mengukur kadar air yang dimiliki oleh lapisan organik Dangkal <50; >=50
7	DC	DC adalah <i>attribut</i> yang dihasilkan dari sistem FWI yang mengukur kadar air yang dimiliki oleh lapisan organik Dalam <50; >=50
8	ISI	ISI adalah skor kecepatan penyebaran api Kecepatan penyebaran api <20 dan Kecepatan Penyebaran api >=20
9	Temp	Temperatur dibagi menjadi 3 bagian cool, mid dan hot cool <10, mild >=10 dan hot >=20
10	RH	Humandity dibagi menjadi low <=25, medium <56 dan hight >=56
11	Wind	Angin True >=4, False <4
12	Rain	Kadar Hujan dibagi 3 bagian, 0, <1 dan >1
13	Area	Area adalah luas area kebakaran dalam satuan hektar 0 hektar dan > 0 hektar. 0 hektar adalah 1 hektar/100=100 m
14	Kelas	Adalah jenis kebakaran yang terjadi 0 untuk kebakaran kecil dan 1 untuk kebakaran besar

3.4 Metode yang digunakan

Dalam penelitian ini metode yang diusulkan adalah menggunakan metode eksperimen dan dalam pengolahan data menggunakan *Algoritma Naïve Bayes* yang dioptimasi menggunakan Algoritma Genetika untuk memprediksi tingkat jenis kebakaran hutan, Berikut adalah tahapan pengolahan data yang diusulkan dalam penelitian ini:



Gambar 3.2 Tahapan Pengolahan Data yang diusulkan

Pada tahapan pengolahan data, langkah pertama yang dilakukan adalah mengumpulkan dataset hasil prediksi kebakaran hutan diolah dari data mentah menjadi data kategorikal atau yang disebut dengan tahapan *Preprocessing*, selanjutnya data dimasukkan kedalam model Naïve Bayes sebagai algoritma yang akan dioptimasi menggunakan Algoritma Genetika, tahapan selanjutnya data diolah dengan menggunakan metode Naïve Bayes dan dioptimasi dengan Algoritma Genetika, yang pada tahapan ini juga dilakukan pembuatan model dengan memilih dan menerapkan teknik serta metode yang akurat untuk mendapatkan hasil yang optimal, tahapan *modelling* dilakukan dengan dua cara yaitu dengan cara manual dan menggunakan *software* Rapid Miner. Pembuatan *modelling* pada *Algoritma Naïve Bayes* dilakukan dengan cara menghitung *probabilitas prior*, kemudian langkah selanjutnya adalah dengan melakukan perhitungan terhadap probabilitas *posterior*. Tahapan berikutnya adalah melakukan pengujian data dengan menggunakan *Tools rapid miner*, dan pada tahapan terakhir melakukan evaluasi terhadap hasil pengujian dengan menggunakan *Confussion matrix* dan *Kurva ROC* untuk mengetahui tingkat akurasi dan melakukan pengukuran terhadap nilai *AUC (Area Under Curve)* untuk mengklasifikasi kriteria dari hasil prediksi.

3.5 Eksperimen dan pengujian metode.

Pada tahapan eksperimen ini dilakukan permodelan untuk melakukan penyelesaian prediksi terhadap kebakaran hutan dengan menerapkan pendekatan metode *Algoritma Naïve Bayes* dan dioptimasi dengan menggunakan algoritma genetika. Dalam permodelan *Naïve Bayes*, langkah pertama yang dilakukan adalah:

mencari *hipotesis* dari *probabilitas* untuk masing-masing *class* $P(H)$, menghitung kondisi tertentu (*probabilitas* X) berdasarkan *probabilitas* tiap *hipotesis* (*probabilitas* H) atau yang dinamakan dengan *probabilitas prior*, selanjutnya setelah diketahui *probabilitas* setiap atribut terhadap *probabilitas* tiap *class* atau $P(X|C_i)$, maka langkah selanjutnya adalah menghitung total keseluruhan *probabilitas* tiap *class*.

Dalam penelitian ini digunakan metode penelitian *Eksperiment*, dimana pada penelitian ini melibatkan penyelidikan hubungan kausal menggunakan testing yang dilakukan oleh peneliti itu sendiri. Untuk menunjang penelitian eksperimen ini digunakan spesifikasi *Software dan Hardware*, seperti yang terlihat pada Tabel 3.3 dibawah ini:

Tabel 3.3 Spesifikasi *Software dan Hardware*

<i>Software</i>	<i>Hardware</i>
<i>Sistem Operasi: Windows 7</i>	<i>CPU: Core i3</i>
<i>Software Data Mining: Rapid Miner 5.3</i>	<i>Memory: 2 GB</i>
	<i>Hardisk: 320 GB</i>

Untuk mendapatkan variable-variabel yang tepat dan menghasilkan nilai akurasi yang terbaik diperlukan pengaturan untuk parameter-parameter *Genetic Optimization*. Berikut adalah parameter-parameter yang membutuhkan *adjustment* (Fauzi, 2011):

1. Ukuran Populasi (*Pop_Size*)
Populasi adalah kumpulan beberapa individu yang sejenis yang hidup dan saling berinteraksi bersama pada suatu tempat. Jumlah individu dinyatakan sebagai ukuran dari populasi tersebut.
2. *P Crossover (Probability Crossover)*
Pada saat proses genetika berlangsung, nilai dari *p crossover* digunakan untuk menentukan individu-individu yang akan mengalami *crossover*.
3. *P Mutation (Probability Mutation)*
Nilai dari *p mutasi* digunakan untuk menentukan individu yang akan mengalami mutasi, terjadi setelah proses *crossover* dilakukan.

3.6 Evaluasi dan Validasi Hasil.

Tahapan terakhir adalah melakukan pengujian dengan cara mengukur menggunakan metode *Confussion Matrix* dan *Kurva ROC* beserta *Area Under Curvenya*. Evaluasi dilakukan untuk mengetahui tingkat akurasi dari model Algortima Naïve Bayes yang dioptimasi dengan algoritma genetika. Selanjutnya dilakukan validasi terhadap data untuk melihat perbandingan hasil akurasi dari model yang telah digunakan dan menggunakan hasil telah ada sebelumnya. Tahapan validasi dilakukan dengan mengukur tingkat akurasi dari algoritma dengan menggunakan *Cofussion Matrix* dan *Kurva ROC* untuk melakukan pengukuran nilai *AUC (Area Under Curve)*.

3.7 Prototype

Setelah dilakukan evaluasi maka selanjutnya adalah pembuatan *prototype* sistem informasi prediksi kebakaran hutan dengan menggunakan metode yang telah diusulkan. Pembuatan *prototype* menggunakan bahasa pemrograman visual basic 6.0.

BAB IV

HASIL DAN PEMBAHASAN

4.1 Hasil Eksperimen dan Pengujian Metode.

Dalam pembuatan model algoritma *Naïve Bayes*, langkah awal yang harus dilakukan adalah terlebih dahulu mencari nilai *probabilitas* hipotesis untuk tiap-tiap *class* $P(H)$. Hipotesis dilakukan terhadap data yang terdiri dari 517 *record* data tersebut adalah data *public* yang didapat dari *University of CaliforniaIrvine machine learning data repository* yang berkaitan dengan kebakaran hutan, hipotesis yang didapatkan yaitu pengklasifikasian data menjadi kebakaran kecil dan kebakaran besar.

Eksperimen yang penulis lakukan dalam penelitian ini adalah dengan menghitung *probabilitas Prior* dan *probabilitas posterior* dengan menggunakan data sebanyak 517 *record*.

4.1.1 Penentuan data traning dan data testing

Penelitian ini menggunakan metode K-fold *Cross Validation* untuk membagi data training dan data testing. Data dibagi menjadi 2 bagian yaitu sebesar 90% dataset untuk metode pelatihan dan 10% dataset akan digunakan untuk metode pengujian.

4.2 Pembahasan

Tujuan penelitian ini adalah untuk mengembangkan model algoritma *Naïve Bayes* dimana didalam penelitian ini data dianalisa dengan menggunakan dua algoritma yaitu algoritma *Naïve Bayes* dan algoritma *Naïve Bayse* berbasis algoritma genetika.

4.2.1 Perhitungan Algoritma Naïve Bayes

A. Menghitung *Probabilitas Prior*

Setelah mendapatkan jumlah data yang akan di olah, maka selanjutnya adalah menghitung *Probabilitas Prior* dan *Probabilitas posterior*, dalam bentuk persamaan dibawah ini:

Total data yang akan di olah	= 517
Data Kebakaran Kecil	= 247
Data Kebakaran Besar	= 270

$$P(\text{Kebakaran Kecil})=247/517 = 0,478$$

$$P(\text{Kebakaran Besar})=270/517 = 0,522$$

Setelah didapatkan nilai *probabilitas* untuk tiap hipotesis dari *class*, maka langkah selanjutnya adalah melakukan penghitungan terhadap kondisi *probabilitas* tertentu (*Probabilitas X*) dengan menggunakan data berdasarkan *probabilitas* tiap hipotesis (*Probabilitas H*) atau yang dinamakan dengan *probabilitas Prior*. Selanjutnya untuk mengetahui hasil perhitungan dari *Probabilitas Prior*, maka dilakukan penghitungan dengan cara merinci jumlah kasus dari tiap-tiap atribut variabel data, adapun hasil perhitungan *probabilitas prior* dengan menggunakan *Algoritma Naïve Bayes* dapat dilihat pada tabel berikut:

Tabel 4.1 Penghitungan *Probabilitas Prior*.

Atribut/ Variabel		Jumlah Data (S)	Kebakaran Kecil	Kebakaran Besar	P(X Ci)	
					Kebakaran Kecil	Kebakaran Besar
Total		517	247	270	0,478	0,522
X	1	48	24	24	0,500	0,500
	2	73	34	39	0,466	0,534
	3	55	32	23	0,582	0,418
	4	91	45	46	0,495	0,505
	5	30	13	17	0,433	0,567
	6	86	37	49	0,430	0,570
	7	60	29	31	0,483	0,517
	8	61	28	33	0,459	0,541
	9	13	5	8	0,385	0,615
Y	2	44	32	12	0,727	0,273
	3	64	26	38	0,406	0,594
	4	203	160	43	0,788	0,212
	5	125	88	37	0,704	0,296
	6	74	35	39	0,473	0,527
	8	1	0	1	0,000	1,000
	9	6	4	2	0,667	0,333
Month	4	9	8	1	0,889	0,111
	8	184	38	146	0,207	0,793
	12	9	0	9	0,000	1,000
	2	20	8	12	0,400	0,600

Atribut/ Variabel		Jumlah Data (S)	Kebakaran Kecil	Kebakaran Besar	P(X Ci)	
					Kebakaran Kecil	Kebakaran Besar
	1	2	1	1	0,500	0,500
	7	32	7	25	0,219	0,781
	6	17	2	15	0,118	0,882
	3	54	46	8	0,852	0,148
	5	2	0	2	0,000	1,000
	11	1	0	1	0,000	1,000
	10	15	15	0	1,000	0,000
	9	172	89	83	0,517	0,483
Day	5	85	38	47	0,447	0,553
	1	74	37	37	0,500	0,500
	6	84	43	41	0,512	0,488
	7	95	32	63	0,337	0,663
	4	61	24	37	0,393	0,607
	2	63	32	31	0,508	0,492
	3	54	23	31	0,426	0,574
FFMC	<80	12	8	4	0,667	0,333
	<90	94	48	46	0,511	0,489
	>=90	408	191	217	0,468	0,532
DCM	<50	105	60	45	0,571	0,429
	>=50	412	187	225	0,454	0,546
DC	<50	29	16	13	0,552	0,448
	>=50	488	231	257	0,473	0,527
ISI	<20	507	243	264	0,479	0,521
	>=20	10	4	6	0,400	0,600
Them	Cool <10	36	15	21	0,417	0,583
	Mid<20	250	139	111	0,556	0,444
	Hot>=20	231	93	138	0,403	0,597
RH	low<25	34	22	12	0,647	0,353
	Medium<56	401	187	214	0,466	0,534
	Hight>=56	82	38	44	0,463	0,537
Wind	<4	249	125	124	0,502	0,498
	>=4	268	122	146	0,455	0,545
Rain	0	509	241	268	0,473	0,527
	<1	5	5	0	1,000	0,000
	>=1	3	1	2	0,333	0,667
Area	=0	274	247	0	1	0

Atribut/ Variabel		Jumlah Data (S)	Kebakaran Kecil	Kebakaran Besar	P(X Ci)	
					Kebakaran Kecil	Kebakaran Besar
	>0	243	0	270	0	1

Setelah mengolah data Probabilitas prior, maka didapatkan dua *class* yang terbentuk yaitu:

Kelas = Kebakaran Kecil

Kelas = Kebakaran Besar

B. Menghitung *Probabilitas Posterior*

Tahapan selanjutnya adalah menghitung *Probabilitas Prior* untuk menentukan *class* terhadap temuan kasus baru, dengan cara terlebih dahulu menghitung *Probabilitas Posterior*nya, hal tersebut dilakukan apabila ditemukan kasus baru dalam pengolahan data. Berikut tabel *probabilitas posterior* untuk menghitung kasus baru yang ditemukan:

Tabel 4.2 Penghitungan *Probabilitas Posterior*

Data X		P(X Ci)	
Atribut	Nilai (Value)	Kebakaran Kecil	Kebakaran Besar
X	1	0,097	0,089
Y	4	0,648	0,159
Month	12	0,000	0,033
Day	1	0,150	0,137
FFMC	>=80	0,194	0,170
DCM	<50	0,243	0,167
DC	>=50	0,935	0,952
ISI	<20	0,984	0,015
Them	<10	0,061	0,078
RH	>=25	0,757	0,793
Wind	<4	0,506	0,459
Rain	>=1	0,976	0,993
Area	>0	0	1,000

Setelah mengetahui nilai *probabilitas* dari setiap atribut terhadap *probabilitas* tiap *class* atau yang dirumuskan dalam bentuk persamaan $P(X|C_i)$, maka langkah berikutnya adalah melakukan penghitungan terhadap total keseluruhan *probabilitas* tiap *class*. Berikut persamaan untuk menghitung probabilitas tiap *class*:

$$P(X|\text{Kelas} = \text{Kebakaran Kecil})$$

$$= 0,097 \times 0,648 \times 0,000 \times 0,150 \times 0,194 \times 0,243 \times 0,935 \times 0,984 \times 0,061 \times 0,757 \times 0,506 \times 0,976 \times 0,000$$

$$= 0.000$$

$$P(X|\text{Kelas}=\text{Kebakaran Besar})$$

$$= 0,089 \times 0,159 \times 0,033 \times 0,137 \times 0,170 \times 0,167 \times 0,952 \times 0,015 \times 0,078 \times 0,793 \times 0,459 \times 0,993 \times 1,00$$

$$= 5,044$$

$$P(X|\text{Kelas}=\text{Kebakaran Kecil})P(\text{Kebakaran Kecil}) = 0 \times 0,478=0$$

$$P(X|\text{Kelas}=\text{Kebakaran Besar})P(\text{Kebakaran Besar}) = 5,044 \times 0,522= 1,362$$


Hasil perhitungan terhadap *probabilitas* tiap *class* diatas, diketahui bahwa nilai $P(X|\text{kebakaran besar})$ lebih besar daripada nilai $P(X|\text{kebakaran kecil})$, sehingga dapat diambil kesimpulan bahwa dalam kasus prediksi kebakaran hutan tersebut akan masuk kedalam klasifikasi kebakaran besar dan tidak termasuk kedalam klasifikasi Kebakaran Kecil.

C. Pengujian Data Menggunakan Rapid Miner

Untuk melihat tingkat akurasi prediksi kebakaran hutan penulis menggunakan rapid miner, berikut gambaran model pengolahan data menggunakan algoritma *naïve bayes*.

1. Melakukan *import* data *forestfair* kedalam rapid miner, dalam tahapan ini pilih *variable* yang akan dijadikan label, ada 14 *variable* yang terdapat di dalam data, yang dijadikan label adalah *variabel* kelas sedangkan 13 *variable* lainnya menjadi *attribut*, untuk *variable* yang dijadikan label *type data* diganti menjadi *binominal*.
2. Tahapan berikutnya data yang sudah berhasil di *import* dimasukan kedalam *main proses*. Selanjutnya memasukan nominal x-validation untuk memvalidasi data


fireforest didalam proses x-validation dibagi 2 bagian yaitu *trening* dan *testing*. Berikut gambaran model x validation.



Gambar 4.1

Model X-Validation


Kemudian *double* klik pada *validation* dan akan masuk kelayar berikutnya, layar berikutnya adalah layar untuk memasukan metode yang akan digunakan. Di dalamnya terdapat 2 layar *testing* dan *trening*. Gambar model sebagai berikut:



Gambar 4.2

Model Naïve Bayes

3. Dengan menggunakan *K-fold cross validation* dimana data dibagi menjadi 2 oleh rapid mainer menjadi data *testing* dan data *training*, model yang telah terbentuk dihitung akurasi dan hasilnya adalah nilai akurasi sebesar 94,58% dan nilai AUC sebesar 0,974.



	true 0	true 1	class precision
pred. 0	246	27	90.11%
pred. 1	1	243	99.59%
class recall	99.60%	90.00%	

Gambar 4.3

Hasil Akurasi Algoritma Naïve Bayes pada Rapid Mainer


Hasil akurasi dari model naïve bayes adalah Nilai TP(*True Positif*) = 243 dan FP(*false Positif*)=27 sedangkan nilai TN(*True Negatif*) =246 dan FN(*False Negativ*)=1. Berikut adalah perhitungan Akurasi, Precision, Recall dan f-Measure adalah sebagai berikut:

$$\text{Akurasi} = \frac{(TN + TP)}{(TN + FN + TP + FP)} = \frac{246 + 243}{246 + 1 + 243 + 27} = 0,9458 = 94,58\%$$

$$\text{Precision} = \frac{(TP)}{(TP + FP)} = \frac{243}{243 + 1} = 0.9959 = 99,59\%$$

$$\text{Recall} = \frac{(TP)}{(TP + FN)} = \frac{243}{243 + 27} = 0.900 = 90,00\%$$

$$\text{f-Measure} = \frac{2 * \text{recall} * \text{precision}}{(\text{recall} + \text{precision})} = \frac{2 * 0,9000 * 0,9959}{0,9000 + 0,9959} = 89,63\%$$



Gambar 4.4
Hasil AUC dengan Menggunakan NB

Dari gambar diatas menunjukan bahwa *area under curva* (AUC) adalah 94,58 % sampai dengan 3,45 % dimana garis merah menunjukan nilai ROC sedangkan garis biru menunjukan nilai bias. Semakin tinggi nilai ROC maka semakin kecil nilai bias.

4.2.2 Perhitungan Optimasi Model dengan Menggunakan Algoritma Genetika

Selanjutnya adalah optimasi dengan menggunakan Algoritma Genetika, dan akan dilakukan perhitungan manual untuk memilih variabel dari *dataset forestfire* berikut adalah sample data 5 *record* sampel data yang akan digunakan dalam perhitungan manual:

Table 4.3 Data Forest Fire

X	Y	month	day	FFMC	DMC	DC	ISI	Temp	RH	wind	rain	area	Type
1	3	8	1	87,6	52,2	103,8	5	8,3	72	3,1	0	0	0
1	2	8	5	90,1	108	529,8	12,5	14,7	66	2,7	0	0	0
2	4	8	3	91,8	175,1	700,7	13,8	25,7	39	5,4	0	0,09	1
8	6	8	3	94,3	131,7	607,1	22,7	19,4	55	4	0	0,17	1
8	6	8	6	90,9	126,5	686,5	7	21,9	39	1,8	0	0,47	1

A. Tahapan perhitungan manual pemilihan variabel data menggunakan Algoritma Genetika.

Sebelum melakukan perhitungan manual untuk pemilihan variabel menggunakan Algoritma Genetika sebelumnya siapkan dulu data sebagai sample sebanyak lima *record* dari *dataset forestfire* seperti yang tertera di dalam tabel diatas. Berikut langkah-langkah perhitungan manual algoritma genetika untuk pemilihan variable:

1. Langkah 1 : Menentukan populasi awal.

C1: [1_3_8_1_87.6_52.2_103.8_5_8.3_73_3.1_0_0]

C2: [1_2_8_5_90.1_108_529.8_12.5_14.7_66_2.7_0_0]

C3: [2_4_8_3_91.8_175.1_700.7_13.8_25.7_39_5.4_0_0.09]

C4: [8_6_3_94.3,131.7_607.7_22.7_19.4_55_4_0_0.17]

C5: [8_6_8_6_90.9_126.5_686.5_7_21.9_39_1.8_0_0.47]

2. Langkah 2 : Evaluasi Nilai *Fitness*.

Fitness C1 = $1/1+(1+3+8+1+87,6+52,2+103,8+5+8,3+72+3,1+0)-1=344$

Fitness C2 = 838,8

Fitness C3 = 1067,59

Fitness C4 = 958,37

Fitness C5 = 1001,07

Dari nilai Fitness diatas, diketahui Total Nilai Fitness = 4209,83

$P[C1] = 344/4209,83 = 0,081714$

$P[C2] = 0,199248$

$P[C3] = 0,253595$

$P[C4] = 0,227651$

$P[C5] = 0,237793$

3. Langkah 3: Seleksi kromosom induk

Untuk proses seleksi menggunakan Roulette Wheel. Tahap awal menentukan nilai kumulatif probabilitas dari setiap kromosom sebagai berikut :

$C1 = 0,081814$ $= 0,081814$

$C2 = 0,081814 + 0,199248$ $= 0,281062$

$C3 = 0,081814 + 0,199248 + 0,253595$ $= 0,534657$

$C4 = 0,081814 + 0,199248 + 0,253595 + 0,227651$ $= 0,762308$

$C5 = 0,081814 + 0,199248 + 0,253595 + 0,227651 + 0,237793$ $= 1$

Langkah selanjutnya adalah, gunakan bilangan acak R antara 0 sampai 1. Bilangan acak yang digunakan sebanyak jumlah kromosom, misalkan sebagai berikut :

$R1 = 0.091$

$R2 = 0.391$

$R3 = 0.821$

$R4 = 0.759$

$R5 = 0.499$

Selanjutnya memilih kromosom ke x sebagai *parent* dengan syarat $C[x-1] < R < C[x]$. Angka acak $R[1] >$ Nilai Kumulatif dari C1, akan tetapi $R[1] <$ dari nilai kumulatif C2.

Sehingga C1 nanti akan dilakukan crossover menjadi :

C1 Menjadi C2 :

[1_2_8_5_90.1_108_529.8_12.5_14.7_66_2.7_0_0]

C2 Menjadi C3 :

[2_4_8_3_91.8_175.1_700.7_13.8_25.7_39_5.4_0_0.09]

C3 Menjadi C5 :

[8_6_8_6_90.9_126.5_686.5_7_21.9_39_1.8_0_0.47]

C4 Menjadi C5 :

[8_6_8_6_90.9_126.5_686.5_7_21.9_39_1.8_0_0.47]

C5 Menjadi C3 :

[2_4_8_3_91.8_175.1_700.7_13.8_25.7_39_5.4_0_0.09]

4. Langkah 4: *Crossover* (Perkawinan Silang)

Dalam *crossover* tentukan Probabilitasnya (pr), yaitu sebesar 0.5 atau 50%.

Hanya kromosom yang nilai R lebih kecil dari 0.5 yang akan bermutasi.

Maka Kromosom ke y akan dipilih menjadi induk jika $R[y] < pr$, dari bilangan acak R diatas maka yang dijadikan parent adalah C1, C2 dan C5. Sedangkan C3 dan C4 > 0.5 , sehingga tidak dilakukan seleksi.

Selanjutnya setelah melakukan pemilihan *parent*, dilanjutkan menentukan kromosom yang akan dilakukan perkawinan silang dengan pengambilan sejumlah atribut 1-13.

Dalam hal ini posisi cut-point (cp) dipilih menggunakan bilangan acak dari 1-13 sesuai banyaknya *crossover* yang terjadi. Misalnya didapatkan posisi *crossover* adalah 6, maka kromosom parent akan dipotong mulai gen ke 6 kemudian potongan gen tersebut saling ditukarkan antar parent.

$C1 \times C2$

$cp(C1) = 6$

cp(C2) = 8

cp(C5)=11

nilai Offspring[1]= C1 >< C2 dengan cp(C1)

= C1: [1_3_8_1_87.6_52.2_103.8_5_8.3_73_3.1_0_0]
><
C2: [1_2_8_5_90.1_108_529.8_12.5_14.7_66_2.7_0_0]
=
C1: [1_3_8_1_87.6_108_103.8_5_8.3_73_3.1_0_0]

nilai Offspring[2]= C2 >< C1 dengan cp(C2)

= C2: [1_2_8_5_90.1_108_529.8_12.5_14.7_66_2.7_0_0]
><
C1: [1_3_8_1_87.6_52.2_103.8_5_8.3_73_3.1_0_0]
=
C2: [1_2_8_5_90.1_108_529.8_5_14.7_66_2.7_0_0]

nilai Offspring[3]= C5 >< C3 dengan cp(C5)

=
C5: [8_6_8_6_90.9_126.5_686.5_7_21.9_39_1.8_0_0.47]
><
C3: [2_4_8_3_91.8_175.1_700.7_13.8_25.7_39_5.4_0_0.09]
=
C5: [8_6_8_6_90.9_126.5_686.5_7_21.9_39_5.4_0_0.47]

Populasi baru yang terbentuk dengan hasil crossover yang telah terjadi menjadi :

C1: [1_3_8_1_87.6_108_103.8_5_8.3_73_3.1_0_0]
C2: [1_2_8_5_90.1_108_529.8_5_14.7_66_2.7_0_0]
C3: [2_4_8_3_91.8_175.1_700.7_13.8_25.7_39_5.4_0_0.09]
C4: [8_6_3_94.3,131.7_607.7_22.7_19.4_55_4_0_0.17]
C5: [8_6_8_6_90.9_126.5_686.5_7_21.9_39_5.4_0_0.47]

5. Langkah 5: Mutasi Kromosom

Jumlah *Chromosom* yang mengalami mutasi dalam satu populasi ditentukan oleh presentase mutation (pm). Proses mutasi dilakukan dengan cara mengganti satu gen yang terpilih secara acak dengan suatu nilai baru yang didapat secara acak.

Total Gen = (Gen dalam Kromosom)* Jumlah Kromosom
= 13 gen * 5 kromosom

= 65

Selanjutnya dilakukan penentuan posisi gen yang mengalami mutasi dengan cara menggunakan bilangan acak antara 1 sampai 65 (sesuai total gen). Kemudian tentukan presentase mutation, misalnya sebesar 10%. Maka jumlah gen yang mengalami mutasi 10% dari 65 adalah 6 gen.

Kemudian menggunakan bilangan acak 0.00 – 1000 untuk mengganti 6 gen yang dipilih secara acak juga. Misalnya posisi gen yang akan diganti adalah 14 – 19 akan di ganti dengan sejumlah nilai secara berurutan [3_2_5_2_8.7_9.9]. Dengan demikian kromosom ke 2 pada gen ke 1 sampai kromosom ke 2 pada gen ke 6. maka hasil yang didapat adalah :

C1: [1_3_8_1_87.6_108_103.8_5_8.3_73_3.1_0_0]

C2: [3_2_5_2_8.7_9.9_529.8_5_14.7_66_2.7_0_0]

C3: [2_4_8_3_91.8_175.1_700.7_13.8_25.7_39_5.4_0_0.09]

C4: [8_6_3_94.3,131.7_607.7_22.7_19.4_55_4_0_0.17]

C5: [8_6_8_6_90.9_126.5_686.5_7_21.9_39_5.4_0_0.47]


Selanjutnya kromosom ke 4 diuji agar menjadi kromosom yang diinginkan. Jika kromosom ke 4 tidak memenuhi syarat, maka semua kromosom dalam populasi ini akan mengalami proses yang sama seperti generasi sebelumnya yaitu proses evaluasi, seleksi, *crossover* dan mutasi yang kemudian akan menghasilkan kromosom-kromosom baru untuk generasi selanjutnya. Gen yang sama dianggap tidak digunakan pada metode selanjutnya dan dibuat bobotnya menjadi 0. Dan Gen yang berbeda pada setiap kromosom digunakan pada metode nantinya dan dibuat bobot menjadi 1.

B. Pengujian Data Model Algoritma Naive Bayes berbasis Algoritma genetika

Berikut adalah gambar K-fold validation untuk model algoritma Naive Bayes berbasis atau dioptimasi dengan menggunakan algoritma genetika.


1. Koneksikan *dataset* dengan model *Optimize Selection (Evolutionary)* kemudian double klik model *Optimize Selection*, selanjutnya masukan x-

validation didalam *Optimize Selection* dan proses yang terakhir masukan model naive bayes dan untuk mengujinya gunakan *applay model dan performance*. Seperti yang tergambar dibawah ini:



Gambar 4.5 Koneksi dataset dengan *Optimaize Selection*


Selanjutnya double klik pada *Optimaize Selection* untuk proses x-validation, didalam proses cross validation data akan dibagi menjadi 10 bagian seperti pada pengujian menggunakan naive bayes diatas, berikut gambar modelnya :



Gambar 4.6

Evaluasi Proses menggunakan X-Validation

Setelah x-validation terkoneksi selanjutnya masuk kedalam proses x-validation dengan cara mendouble klik x-validation. Berikut adalah model naive bayes yang dioptimasi dengan algoritma genetika:



Gambar 4.7

Model Optimasi Naive Bayes berbasis Algoritma Genetika

- Hasil akurasi yang didapat dari model optimasi algoritma naive bayes yang dioptimasi dengan algoritma genetika adalah 94,80%. Berikut table confusen metrix model Naive Bayes berbasis algoritma genetika:

/KolaborasiBandGA* - RapidMiner 5.3.013 @ DWX-PC

Tools View Help

PerformanceVector (Performance) ExampleSet (Optimize Selection (Evolutionary))

Text View Annotations

Multiclass Classification Performance Annotations

Table View Plot View

accuracy: 94.80% +/- 3.94% (mikro: 94.78%)

	true 0	true 1	class precision
pred. 0	247	27	90.15%
pred. 1	0	243	100.00%
class recall	100.00%	90.00%	

Gambar 4.8

Hasil Confussion Matrix dari model NB berbasis GA


$$\text{Akurasi} = \frac{(TN + TP)}{(TN + FN + TP + FP)} = \frac{247 + 243}{247 + 0 + 243 + 27} = 0,9477 = 94,80\%$$

$$\text{Precision} = \frac{(TP)}{(TP + FP)} = \frac{243}{243 + 0} = 1 = 100\%$$

$$\text{Recall} = \frac{(TP)}{(TP + FN)} = \frac{243}{243 + 27} = 0.900 = 90,00\%$$

$$\text{f-Measure} = \frac{2 * \text{recall} * \text{precision}}{(\text{recall} + \text{precision})} = \frac{2 * 0,900 * 1}{0,9000 + 1} = 94,74\%$$

3. Sedangkan nilai *area under curva* (AUC) adalah 0,960 sampai dengan 0,032. Garis merah menunjukkan ROC sedangkan garis biru menunjukkan nilai bias, berikut adalah gambar curva AUC.



Gambar 4.9

Hasil AUC Naive Bayes berbasis Algoritma Genetika

4.3 Hasil Penelitian

4.3.1 Hasil Pengujian dengan *Confusen Matrix*

Pada percobaan pertama menggunakan algoritma naïve bayes terlebih dahulu tanpa menggunakan algoritma genetika untuk seleksi fitur. Percobaan menggunakan 517 data dan 14 atribut prediktor yang telah dinormalisasikan menjadi data numerik,

attribut-attribut tersebut adalah x, y, day, month, FFMC, DMC, DC, ISI, wind, RH, rain, area, dan temp serta untuk pengujian digunakan K-Fold cross validation untuk validasi dan *confusion matrix* untuk menghitung tingkat akurasi.


Hasil yang didapat dari percobaan menggunakan Naïve Bayes nilai akurasi yang didapatkan adalah 94,58 % sedangkan nilai AUC(*are under curva*) adalah 0,974.

Selanjutnya adalah percobaan dengan menggunakan Naïve Bayes dengan Algoritma Genetika, hasil akurasi yang didapatkan dengan nilai *maximum number of generation* 30, nilai *Pop Size* 5, *P Mutation* 0.5 dan Nilai *Crossover* -1,0 hasil akurasi yang di dapat adalah 94,80% dan AUC(*area under curva*) adalah 0,956.

4.3.2 Hasil Perbandingan Naïve Bayes dan Naïve Bayes berbasis Algoritma Genetika

A. Perbandingan dengan *confusion matrix*

Berikut adalah hasil akurasi dari model naïve bayes untuk memprediksi kebakaran hutan:



	true 0	true 1	class precision
pred. 0	246	27	90.11%
pred. 1	1	243	99.59%
class recall	99.60%	90.00%	

accuracy: 94.58% +/- 3.45% (mikro: 94.58%)

Gambar 4.10


Confussion Metrix Model Naïve Bayes

Confusion matrix membentuk matriks yang terdiri dari true positif atau tupel positif dan true negatif atau tupel negatif. Pada table 4.5 , akurasi NB sebesar 94.58 % . dimana Jumlah True Positive (TP) adalah 243 , Untuk False Negative (FN) adalah 246 , untuk False Positive (FP) adalah 1 dan Untuk True Negative (TN) adalah 27.

Table 4.4 Hasil *Confussion Metrix* Naive Bayes

	True Kebakaran Kecil	True Kebakaran Besar	Class Precision
Kebakarn Kecil	243	27	99,11%
Kebakaran Besar	1	246	99,59%
<i>Class recall</i>	99,60%	90,00%	
<i>Accuracy</i>	94,58%		

Sedangkan untuk pengujian model Naïve Bayes berbasis Algoritma Genetika berikut adalah hasil *confussion matrixnya* :



accuracy: 94.80% +/- 3.94% (mikro: 94.78%)			
	true 0	true 1	class precision
pred. 0	247	27	90.15%
pred. 1	0	243	100.00%
class recall	100.00%	90.00%	

Gambar 4.11

Hasil *Confussion Matrix* Menggunakan *Naïve Bayes* berbasis Algoritma Genetika


Confusion matrix membentuk matriks yang terdiri dari *true positif* atau tupel positif dan *true negatif* atau tupel negatif. Pada gambar 4.6 , akurasi NB berbasis GA sebesar 94.80 %. dimana Jumlah True Positive (TP) adalah 243 , Untuk False Negative (FN) adalah 247 , untuk False Positive (FP) adalah 0 dan Untuk True Negative (TN) adalah 27.

Table 4.5 Hasil *Confussion Metrix* NB +GA

	Kebakaran Kecil	Kebakaran Besar	<i>Class Precision</i>
Kebakarn Kecil	243	27	99,15%
Kebakaran Besar	0	247	100%
<i>Class recall</i>	100%	90,00%	
<i>Accuracy</i>	94,80%		


B. Evaluasi dengan Kurva ROC

Dibawah ini adalah kurva AUC dengan menggunakan model Naïve Bayes dan kurva AUC model Naïve Bayes berbasis Algoritma Genetika:



Gambar 4.12

Curva AUC model Naïve Bayes



Gambar 4.13

Curva AUC model Naïve Bayes berbasis Algoritma Genetika

Pada Gambar 4.12 menunjukkan grafik ROC dengan nilai AUC (*Area Under Curve*) sebesar 0.974 dengan tingkat diagnosa *Excellent Classification* untuk model naive bayes sedangkan untuk model naive bayes berbasis algoritma genetika pada gambar 4.13 menunjukkan bahwa AUC (*Area Under Curva*) sebesar 0,977 dengan tingkat diagnosa *Excellent Classification*.

Hasil uji coba model naive bayes dan naive bayes berbasis algoritma genetika untuk memprediksi kebakaran hutan adalah sebagai berikut:

Table 4.6 Nilai Akurasi dan AUC Hasil Uji Coba NB dan NB+GA

Model	Akurasi	AUC
Naive Bayes	94,58 %	0,974
Naive Bayes + Algoritma Genetika	94,80%	0,977
Selisih Akurasi	0,22%	0,03

4.4 Perancangan dan Pengujian Prototype

Tahapan berikutnya adalah pembuatan dan pengujian prototype, untuk pembuatan prototype prediksi kebakaran hutan menggunakan bahasa pemrograman visual basic 6.0, prototype ini dapat memprediksi kebakaran kecil atau kebakaran besar. Berikut ini adalah prototype yang penulis buat:

Form Prediksi Kebakaran Hutan

Keterangan

Prediksi Kebakaran Hutan

Variable Titik Koordinat Peta

X (Spatia Coodinate within the Montesinho park map:1-9):

Y (Spatia Coodinate within the Montesinho park map:2-9):

Variable Waktu

Day [1-7]:

Month [1-12]:

Variable FWI System

FFMC (Fine Fuel Moisture Code) - [18,7 to 96,20]:

DMC (Duff Moisture Code) [1.1 to 291.3]:

DC (Drought Code) [7.9 to 860.6]:

ISI (Initial Spread Index) [0.0 to 56.10]:

Variable Meteorology

Themperatur [2.2 to 33.30]: Celsius

RH (Relatif Humandity) [15.0 to 100]: %

Wind [0.40 to 9.40]: Km/H

Rain [0.0 to 6.4]: mm/m2

Area: Hektar

Prediksi:

[Hasil]

Hasil

Kebakaran Kecil:

Kebakaran Besar:

PROSES BERSIH KELUAR

Gambar 4.14

Prototype Prediksi Kebakaran Hutan

Setelah *prototype* dibuat selanjutnya dilakukan pengujian untuk mengevaluasi *prototype*. *Prototype* telah diuji dengan mencoba memasukan 10 sample dari *datasate* dan hasilnya adalah tepat sesuai dengan prediksi yang ada. Untuk melakukan pengujian penulis menyebarkan kuesioner kepada *user* dalam hal ini adalah

masyarakat umum karena data yang diambil penulis adalah data *public*. Kuesioner dirancang sesuai dengan metode SQA (*Software quality Assurance*)

Responden yang mengisi kuesioner sebanyak 5 orang, yang terdiri dari dosen rekayasa perangkat lunak, mahasiswa magister ilmu komputer, instruktur laboratorium dan IT Quality Assurance. Hasil dari kuesioner tersebut dapat dilihat pada table 4.7 berikut:

Table 4.7 Hasil evaluasi SQA

<i>User</i>	<i>Skor Metric</i>								<i>Skor</i>
	1	2	3	4	5	6	7	8	
#1	60	60	60	60	60	78	80	80	67,3
#2	60	79	60	60	60	95	85	79	72,3
#3	78	60	58	60	60	95	85	80	72
#4	60	60	59	60	60	79	79	79	67
#5	60	60	60	75	79	88	89	80	73,9
Skor Rata-Rata									70,5

Untuk menghitung nilai optimal dari kualitas perangkat lunak, maka digunakan rumus skor rata-rata dibawah ini:

$$\text{Skor} = \langle \text{Skor auditability} \rangle * 0.125 + \langle \text{Skor Accuracy} \rangle * 0.125 + \langle \text{Skor Completeness} \rangle * 0.125 + \langle \text{Skor Tolerance} \rangle * 0.125 + \langle \text{Skor Execution Efficiency} \rangle * 0.125 + \langle \text{Skor Operability} \rangle * 0.125 + \langle \text{Skor Simplicity} \rangle * 0.125 + \langle \text{Skor Training} \rangle * 0.125.$$

Dari hasil penghitungan diatas, didapatkan skor rata-rata adalah mencapai 70,05, dan sudah melebihi nilai optimal untuk sebuah perangkat lunak yang memenuhi standar kualitas berdasarkan uji SQA.

Selanjutnya penilaian dari responden pada tabel SQA diatas diberi nilai berdasarkan kriteria dari skala *likert*, setelah dikalikan lalu dijumlahkan dan dicari rata-rata dari setiap jawaban responden tersebut, maka dibuatlah interval, dalam penelitian ini penulis menentukan banyak kelas interval sebesar 5.


Tabel 4.8 Hasil evaluasi SQA dalam penilaian skala *Likert*

<i>User</i>	Skor <i>Metric</i>							
	1	2	3	4	5	6	7	8
#1	3	3	3	3	3	4	4	4
#2	3	4	3	3	3	5	5	4
#3	4	3	3	3	3	5	5	4
#4	3	3	3	3	3	4	4	4
#5	3	3	3	4	4	5	5	4

Berdasarkan data dari tabel 4.8 diatas, maka penulis melakukan perhitungan dari masing-masing metric yang telah dinilai oleh *user*:

Tabel 4.9 Hasil perhitungan Skala *Likert* Penelitian tiap *Metric*

No	Metriks	Skala Penilaian					Jumlah Jawaban
		SO	O	CO	TO	STO	
1	<i>Auditability</i>	0	1	4	0	0	5
2	<i>Accuracy</i>	0	1	4	0	0	5
3	<i>Completeness</i>	0	0	5	0	0	5
4	<i>Error Tolerance</i>	0	1	4	0	0	5
5	<i>Execution Efficiency</i>	0	1	4	0	0	5
6	<i>Operability</i>	3	2	0	0	0	5
7	<i>Simplicity</i>	3	2	0	0	0	5
8	<i>Training</i>	0	5	0	0	0	5



Gambar 4.15

Grafik Perhitungan Skala *Likert* Penelitian Tiap Metrik

Berdasarkan tabel 4.9 dan grafik pada gambar 4.15, maka penulis melakukan analisa sebagai berikut:

- 1) Pada matrik *auditability*, 1 *user* menilai bahwa aplikasi prediksi kebakaran hutan optimal dan 4 *user* menilai sudah cukup optimal, berarti dapat dikatakan bahwa aplikasi tersebut sudah memenuhi standard.
- 2) Pada matrik *Accuracy*, 1 *user* menilai bahwa aplikasi prediksi kebakaran hutan sudah optimal dan 4 *user* menilai sudah cukup optimal, berarti dapat dikatakan bahwa aplikasi tersebut sudah memiliki keakuratan dalam komputasi.
- 3) Pada matrik *Completeness*, 5 *user* menilai bahwa aplikasi prediksi kebakaran hutan sudah cukup optimal, berarti dapat dikatakan bahwa aplikasi tersebut telah memiliki kelengkapan menu-menu yang dibutuhkan oleh *user*.
- 4) Pada matrik *Error Tolerance*, 1 *user* menilai bahwa aplikasi prediksi kebakaran hutan sudah optimal, dan 4 *user* menilai sudah cukup optimal, berarti dapat dikatakan bahwa aplikasi tersebut memiliki toleransi yang baik terhadap kesalahan.

- 5) Pada matrik *execution Efficiency*, 1 *user* menilai bahwa aplikasi prediksi kebakaran hutan sudah optimal, dan 4 *user* menilai sudah cukup optimal, berarti dapat dikatakan bahwa aplikasi tersebut memiliki kinerja yang baik dalam melakukan eksekusi.
- 6) Pada matrik *Operability*, 3 *user* menilai bahwa aplikasi prediksi kebakaran hutan sudah sangat optimal, dan 2 *user* menilai sudah optimal, berarti dapat dikatakan bahwa aplikasi tersebut mudah untuk dioperasikan.
- 7) Pada matrik *Simplicity*, 3 *user* menilai bahwa aplikasi prediksi kebakaran hutan sudah sangat optimal, dan 2 *user* menilai sudah optimal, berarti dapat dikatakan bahwa aplikasi tersebut memiliki tampilan yang sederhana sehingga mudah untuk digunakan oleh user.
- 8) Pada matrik *Training*, 5 *user* menilai bahwa aplikasi prediksi kebakaran hutan sudah optimal, berarti dapat dikatakan bahwa menu-menu yang ada diaplikasi tersebut mudah untuk dipelajari.

Berdasarkan data diatas dapat disimpulkan bahwa : dari delapan (8) metric yang digunakan untuk mengukur optimalisasi aplikasi prediksi kebakaran hutan menggunakan Visual Basic 6.0 dapat dinyatakan matrik *simplicity*, *operability* dan *training* yang paling optimal karena aplikasi memiliki user interface yang sederhana sehingga mudah digunakan, kemudahan dioperasikan dan mudah untuk dipelajari. Sedangkan matrik yang dianggap paling tidak optimal adalah matrik *accuracy*, *auditability*, *completeness*, *error tolerance* dan *execution efficiency* karena aplikasi yang dirancang masih dalam bentuk prototype sehingga masih banyak menu-menu dan bagian yang belum lengkap.

4.5 Implikasi Penelitian

Dari hasil penelitian ini dapat dinyatakan bahwa pengujian model Naïve Bayes berbasis Algoritma genetika akurasi meningkat dalam prediksi kebakaran hutan dengan nilai *Confusion matrix* 94,58 untuk algoritma naïve bayes dan 94,80 untuk algoritma naïve bayes berbasis algoritma genetika, akursi meningkat sebanyak 0,22%

sedngkan nilai AUC (*Area Under Curva*) adalah 0,974 dan 0,977 selisih AUC adalah 0,03 masih dalam tingkat prediksi *Excellent Classification*.

Hasil penelitian ini memiliki aspek implikasi terhadap penelitian lanjutan:

1. Implikasi terhadap aspek sistem pendukung keputusan.

Prediksi kebakaran hutan penelitian menggunakan algoritma Naïve Bayes berbasis algoritma genetika terbukti dapat meningkatkan hasil prediksi kebakaran hutan sehingga sistem pendukung keputusan ini dapat diterapkan dan dikembangkan agar *software* lebih berkualitas dan sesuai dengan standar *Software quality Assurance*.

2. Implikasi terhadap manajerial

Prediksi kebakaran hutan menggunakan algoritma naïve bayes dan dioptimasi dengan algoritma genetika terbukti memiliki akurasi yang tinggi, sehingga dapat digunakan untuk pengambilan keputusan dalam memprediksi kebakaran hutan dan dapat diterapkan di departemen kehutanan.

3. Implikasi terhadap aspek penelitian

Penelitian ini memiliki prediksi terbaik saat ini dibandingkan dengan penelitian sebelumnya. Model ini juga dapat digunakan untuk memprediksi *dataset* lain selain *dataset forasefire* dan penelitian ini dapat dikembangkan dengan model atau algoritma yang lainnya.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini melakukan pengujian dengan menggunakan model Naïve Bayes yang dioptimasi dengan menggunakan Algoritma Genetika untuk memprediksi kebakaran hutan. Hasil penelitian ini telah membuktikan bahwa pengujian model Naïve Bayes menghasilkan akurasi prediksi sebesar 94,58% sedangkan setelah dioptimasi dengan menggunakan Algoritma Genetika sebagai fitur seleksi *attribut* tingkat akurasinya menjadi 94,80%, sedangkan nilai AUC (*Area Under Curva*) untuk Naïve Bayes adalah 0,74% sedangkan penggunaan model Naïve Bayes yang telah dioptimasi dengan Algoritma Genetika menjadi 0,97%. Sehingga model Naïve Bayes yang dioptimasi dengan Algoritma Genetika sebagai fitur seleksi memiliki nilai akurasi lebih tinggi.

5.2 Saran

Penerapan model Naïve Bayes yang dioptimasi dengan Algoritma Genetika sebagai fitur seleksi terbukti dapat meningkatkan optimasi, namun dari penelitian ini dapat dikembangkan kembali untuk penelitian berikutnya, seperti:

1. Melakukan penelitian dengan metode-metode lain sehingga dapat dibandingkan hasilnya dengan penelitian ini.
2. Melakukan penelitian dengan menggunakan algoritma fitur seleksi atau algoritma optimasi yang lain
3. Penelitian ini diharapkan dapat diterapkan kedalam data lokal, sehingga dapat menjadi salah satu sistem pengambil keputusan untuk departemen kehutanan di Indonesia.
4. Melakukan pengembangan Sistem Informasi Prediksi Kebakaran Hutan sesuai dengan standar *Software quality Assurance*.

DAFTAR PUSTAKA

- Anita, Desiani., Arham, Muhammad. (2006). Konsep Kecerdasan Buatan. Yogyakarta: Cv. Andi Offset.
- Bramer, Max. (2007). *Principles of Data Mining*. London: Springer. ISBN-10: 1-84628-765-0, ISBN-13: 978-1-84628-765-7.
- Cortez, Paul dan Morais, Anibal. (2007). *A Data Mining Approach to Predict Forest Fires using Meteorologi Data*.
- Dawson, C. W. (2009). *Projects In Computing And Information System A Student's Guide*. England: Addison-Wesley.
- Fauzi Rahman, Riza. (2011). Optimalisasi Antrian Pembelian Karcis Di Stasiun Bandung Dengan Menggunakan Algoritma Genetika. Skripsi. Jakarta: UPI.
- Gorunescu, F. (2011). *Data Mining Concepts, Model and Technique*. Berlin: Springer.
- Han, J., Kamber, M. (2006). *Data Mining Concepts and technique*. San Francisco: Diane Cerra.
- Iyer, Vasanth dkk. (2011). *Machine Learning and Datamining Algoritms for Predicting Accidental Small Forest Fires*.
- Kusrini., E. T. Luthfi. (2009). Algoritma Data Mining, 1st ed. Yogyakarta, Indonesia: Andi, .
- Dewi, Sri Kusuma. (2003). *Artificial Intelligent*. Yogyakarta : Graha Ilmu.
- Powers, D.M.W. (2011). *Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation*. Journal of Machine Learning Technologies, ISSN: 2229-3981 & ISSN: 2229-399X, Volume 2, Issue 1, 2011, pp-37-63.
- Riduwan. (2008). Metode dan Teknik Menyusun Tesis. Alfabeta. Bandung

- Sugiyono.(2010). Metode penelitian Kuantitatif Kualitatif dan R&D, Penerbit Alfabeta
- Suyanto.(2007). Artificial Intelligent, Searching, Reasoning Planning dan Learning. Bandung: Informatika Bandung.
- Widodo, Prabowo Pudjo. Penerapan Data Mining dengan Matlab.Bandung: Rekayasa Sains, (2013)
- Vercellis, Carlo. (2009). *Business Intelligence: Data Mining and Optimization for Decision Making*. United Kingdom: John Willey & Son.
- Wahyuni, Diana Tri., Sutojo, T., Luthfiarta, Ardytha.(2014). Prediksi Hasil Pemilu Legislatif DKI Jakarta Menggunakan Naïve Bayes dengan Algoritma sebagai Fitur Seleksi.
- Williams, AAJ., Karoly,DJ., Tapper,N (2001). *The Sensitivity of Australian Fire Danger to Climate Change*. Clim. Change, 49: 171-191.
- Witten, I. H., Frank, E.,Hall, M. A. (2011). *Data Mining: Practical Machine Learning and Tools*. Burlington: Morgan Kaufmann Publisher.
- <http://archive.ics.uci.edu/> , *Forest Fires Dataset*.
- Zukhri, Zainudin.(2014). Algoritma Genetika Metode Komputasi untuk Menyelesaikan Maslah Optimasi.Yogyakarta: Andi Offset.

Lampiran 1 Data Kebakaran Hutan

X	Y	month	day	FFMC	DMC	DC	ISI	temp	RH	wind	rain	area	Kelas
2	5	8	4	18,7	1,1	171,4	0	5,2	100	0,9	0	0	0
6	5	8	3	50,4	46,2	706,6	0,4	12,2	78	6,3	0	0	0
2	2	8	3	53,4	71	233,8	0,4	10,6	90	2,7	0	0	0
6	5	8	5	63,5	70,8	665,3	0,8	17	72	6,7	0	0	0
5	4	8	2	96,1	181,1	671,2	14,3	33,3	26	2,7	0	40,54	1
4	6	2	6	68,2	21,5	87,2	0,8	15,4	40	2,7	0	0	0
3	4	4	6	69	2,4	15,5	0,7	17,4	24	5,4	0	0	0
3	4	4	3	94,9	130,3	587,1	14,1	33,1	25	4	0	26,43	1
4	4	9	6	96,2	175,5	661,8	16,8	32,6	26	3,1	0	2,77	1
5	4	8	7	79,5	3	106,7	1,1	11,8	31	4,5	0	0	0
4	4	7	2	79,5	60,6	366,7	1,5	23,3	37	3,1	0	0	0
3	4	4	3	96,1	181,1	671,2	14,3	32,3	27	2,2	0	14,68	1
6	3	2	5	96	164	643	14	30,8	30	4,9	0	8,59	1
2	4	9	7	95	135,5	596,3	21,3	30,6	28	3,6	0	2,07	1
7	4	9	6	93,2	114,4	560	9,5	30,2	25	4,5	0	2,75	1
7	4	7	6	93,4	145,4	721,4	8,1	29,6	27	2,7	0	1,46	1
5	4	7	3	88,9	263,1	795,9	5,2	29,3	27	3,6	0	6,3	1
2	4	8	7	81,6	56,7	665,6	1,9	27,8	35	2,7	0	0	0
9	9	7	2	81,9	3	7,9	3,5	13,4	75	1,8	0	0	0
2	4	1	6	82,1	3,7	9,3	2,9	5,3	78	3,1	0	0	0
2	5	9	1	83	23,3	85,3	2,3	16,7	20	3,1	0	0	0
2	4	9	7	94,5	139,4	689,1	20	29,2	30	4,9	0	1,95	1
3	4	2	6	83,9	8	30,2	2,6	12,7	48	1,8	0	0	0
1	3	8	5	94,5	139,4	689,1	20	28,9	29	4,9	0	49,59	1
2	2	2	1	84	9,3	34	2,1	13,9	40	5,4	0	0	0
8	6	10	3	84,1	7,3	52,8	2,7	14,7	42	2,7	0	0	0
2	5	8	5	84,1	4,6	46,7	2,2	5,3	68	1,8	0	0	0
9	9	2	4	84,2	6,8	26,6	7,7	6,7	79	3,1	0	0	0
7	6	7	2	93,4	145,4	721,4	8,1	28,6	27	2,2	0	1,61	1
4	6	12	7	84,4	73,4	671,9	3,2	24,2	28	3,6	0	0,96	0
6	5	8	2	93,5	149,3	728,6	8,1	28,3	26	3,1	0	64,1	1
3	4	9	2	84,4	73,4	671,9	3,2	17,9	45	3,1	0	0	0
7	5	8	6	93,6	97,9	542	14,4	28,3	32	4	0	8,85	1
8	6	8	1	95,2	217,7	690	18	28,2	29	1,8	0	5,86	1
4	5	2	6	93,3	49,5	297,7	14	28	34	4,5	0	8,16	1
1	4	9	4	92,1	207	672,6	8,2	27,9	33	2,2	0	2,35	1
6	5	4	7	84,7	8,2	55	2,9	14,2	46	4	0	0	0
8	5	10	1	84,9	32,8	664,2	3	16,7	47	4,9	0	0	0
2	4	8	7	81,6	56,7	665,6	1,9	27,8	32	2,7	0	6,44	1
1	2	8	4	93,5	149,3	728,6	8,1	27,8	27	3,1	0	95,18	1

X	Y	month	day	FFMC	DMC	DC	ISI	temp	RH	wind	rain	area	Kelas
8	3	9	2	84,9	27,5	353,5	3,4	4,2	51	4	0	0	0
1	4	8	6	94,8	222,4	698,6	13,9	27,5	27	4,9	0	746,28	1
6	4	8	4	85,1	28	113,8	3,5	11,3	94	4,9	0	0	0
4	4	8	2	95,9	158	633,6	11,3	27,5	29	4,5	0	43,32	1
1	3	8	4	96,1	181,1	671,2	14,3	27,3	63	4,9	6,4	10,82	1
3	6	6	5	93,5	85,3	395	9,9	27,2	28	1,3	0	1,76	1
2	4	8	3	93,1	180,4	430,8	11	26,9	28	5,4	0	86,45	1
6	5	9	2	93,7	231,1	715,1	8,4	26,9	31	3,6	0	4,96	1
6	5	9	5	91	163,2	744,4	10,1	26,7	35	1,8	0	5,8	1
4	3	8	3	92,9	133,3	699,6	9,2	26,4	21	4,5	0	88,49	1
6	5	8	3	85,8	48,3	313,4	3,9	18	42	2,7	0	0,36	0
4	5	4	5	85,9	19,5	57,3	2,8	12,7	52	6,3	0	0	0
4	4	4	5	85,9	19,5	57,3	2,8	13,7	43	5,8	0	0	0
7	5	4	5	86,2	26,2	94,3	5,1	8,2	51	6,7	0	0	0
6	4	4	6	86,3	27,4	97,1	5,1	9,3	44	4,5	0	0	0
9	9	2	5	86,6	13,2	43	5,3	15,7	43	3,1	0	0	0
2	2	2	5	86,6	13,2	43	5,3	12,3	51	0,9	0	0	0
8	6	8	6	93	103,8	316,7	10,8	26,4	35	2,7	0	10,08	1
4	5	8	4	95,1	141,3	605,8	17,7	26,4	34	3,6	0	16,4	1
2	4	4	2	92,7	164,1	575,8	8,9	26,3	39	3,1	0	7,02	1
6	5	8	5	91,7	191,4	635,9	7,8	26,2	36	4,5	0	185,76	1
4	6	4	1	87,2	23,9	64,7	4,1	14	39	3,1	0	0	0
4	4	4	1	87,2	23,9	64,7	4,1	11,8	35	1,8	0	0	0
1	2	7	6	87,5	77	694,8	5	22,3	46	4	0	0	0
9	5	6	3	93,7	101,3	423,4	14,7	26,1	45	4	0	7,36	1
4	6	12	5	92,1	207	672,6	8,2	25,5	29	1,8	0	1,23	1
4	4	4	1	87,6	52,2	103,8	5	11	46	5,8	0	0	0
1	3	8	1	87,6	52,2	103,8	5	8,3	72	3,1	0	0	0
3	5	4	1	87,6	52,2	103,8	5	9	49	2,2	0	0	0
2	4	9	3	91,6	104,2	474,9	9	25,3	39	0,9	0	8	1
6	3	11	2	92,5	121,1	674,4	8,6	25,1	27	4	0	1090,8	1
1	4	9	2	88	17,2	43,5	3,8	15,2	51	2,7	0	0	0
3	4	4	2	88,1	25,7	67,6	3,8	15,8	27	7,6	0	0	0
3	5	4	2	88,1	25,7	67,6	3,8	15,5	27	6,3	0	0	0
3	5	4	2	88,1	25,7	67,6	3,8	14,9	38	2,7	0	0	0
4	4	4	2	88,1	25,7	67,6	3,8	14,1	43	2,7	0	0	0
6	5	9	4	92	203,2	664,5	8,1	24,9	42	5,4	0	2,44	1
3	4	2	3	90,1	68,6	355,2	7,2	24,8	29	2,2	0	1,36	1
3	4	8	6	88,2	55,2	732,3	11,6	15,2	64	3,1	0	0,52	0
4	3	9	1	91,6	181,3	613	7,6	24,8	36	4	0	3,05	1
6	3	9	1	88,6	91,8	709,9	7,1	11,2	78	7,6	0	0	0
5	5	8	7	92,4	105,8	758,1	9,9	24,8	28	1,8	0	14,29	1

X	Y	month	day	FFMC	DMC	DC	ISI	temp	RH	wind	rain	area	Kelas
4	5	9	1	88,6	91,8	709,9	7,1	17,4	56	5,4	0	0	0
6	3	9	5	88,6	69,7	706,8	5,8	20,6	37	1,8	0	0	0
2	5	7	7	90,1	51,2	424,1	6,2	24,6	43	1,8	0	1,43	1
3	4	8	2	88,8	147,3	614,5	9	14,4	66	5,4	0	0	0
5	4	8	2	88,8	147,3	614,5	9	17,3	43	4,5	0	0	0
2	5	9	1	91,6	181,3	613	7,6	24,6	44	4	0	3,2	1
8	6	7	7	94,8	108,3	647,1	17	24,6	22	4,5	0	10,01	1
6	4	4	3	89,2	27,9	70,8	6,3	15,9	35	4	0	0	0
2	2	4	7	89,3	51,3	102,2	9,6	5,5	59	6,3	0	0	0
9	4	7	1	94,8	108,3	647,1	17	24,6	22	4,5	0	8,71	1
2	2	4	7	89,3	51,3	102,2	9,6	11,5	39	5,8	0	0	0
4	6	4	7	89,3	51,3	102,2	9,6	10,6	46	4,9	0	0	0
8	6	4	7	89,3	51,3	102,2	9,6	11,4	99	1,8	0	0	0
7	4	9	3	89,4	266,2	803,3	5,6	17,4	54	3,1	0	0	0
4	4	4	6	89,4	253,6	768,4	9,7	14,2	73	2,7	0	0	0
7	4	8	4	89,6	84,1	714,3	5,7	17,1	53	5,4	0	0,41	0
7	5	8	2	90,5	61,1	252,6	9,4	24,5	50	3,1	0	70,32	1
2	4	8	5	84,4	73,4	671,9	3,2	24,3	36	3,1	0	105,66	1
6	3	4	6	89,6	84,1	714,3	5,7	19	52	2,2	0	0	0
3	4	9	5	89,7	284,9	844	10,1	10,5	77	4	0	0	0
3	4	9	7	89,7	90	704,4	4,8	22,8	39	3,6	0	0	0
7	4	8	6	89,7	287,2	849,3	6,8	19,4	45	3,6	0	0	0
5	4	9	5	91,6	181,3	613	7,6	24,3	33	3,6	0	3,63	1
4	4	9	7	89,7	90	704,4	4,8	17,8	64	1,3	0	0	0
4	4	8	5	90	51,3	296,3	8,7	16,6	53	5,4	0	0,71	0
7	4	10	5	90	41,5	682,6	8,7	11,3	60	5,4	0	0	0
3	4	8	5	90,1	108	529,8	12,5	21,2	51	8,9	0	0,61	0
2	5	8	2	90,1	39,7	86,6	6,2	13,2	40	5,4	0	0,95	0
4	4	9	3	90,1	82,9	735,7	6,2	12,9	74	4,9	0	0	0
6	5	4	3	92,9	133,3	699,6	9,2	24,3	25	4	0	9,41	1
3	4	4	1	90,1	39,7	86,6	6,2	10,6	30	4	0	0	0
6	4	8	5	92,2	102,3	751,5	8,4	24,2	27	3,1	0	6,58	1
7	4	2	5	95,2	131,7	578,8	10,4	24,2	28	2,7	0	8,68	1
2	4	9	7	95,1	141,3	605,8	17,7	24,1	43	6,3	0	2	1
1	2	8	5	90,1	108	529,8	12,5	14,7	66	2,7	0	0	0
6	5	9	6	92,4	124,1	680,7	8,5	23,9	32	6,7	0	5,33	1
2	2	8	2	94,2	117,2	581,1	11	23,9	41	2,2	0	8,02	1
4	5	9	2	89,6	84,1	714,3	5,7	23,8	35	3,6	0	5,18	1
4	4	8	6	90,2	96,9	624,2	8,9	18,4	42	6,7	0	0	0
6	5	8	6	90,2	96,9	624,2	8,9	14,7	59	5,8	0	0	0
7	4	8	6	90,2	110,9	537,4	6,2	19,5	43	5,8	0	0	0
5	4	2	5	91,8	170,9	692,3	13,7	23,7	40	1,8	0	1,38	1

X	Y	month	day	FFMC	DMC	DC	ISI	temp	RH	wind	rain	area	Kelas
4	4	12	1	93,7	80,9	685,2	17,9	23,7	25	4,5	0	1,12	1
9	6	8	4	93,7	231,1	715,1	8,4	23,6	53	4	0	6,43	1
4	5	8	7	90,2	99,6	631,2	6,3	21,4	33	3,1	0	0	0
8	6	9	1	92,2	102,3	751,5	8,4	23,5	27	4	0	3,33	1
2	2	8	7	90,2	99,6	631,2	6,3	20,8	33	2,7	0	0	0
1	2	8	7	90,2	99,6	631,2	6,3	17,9	44	2,2	0	0	0
4	3	8	7	90,2	99,6	631,2	6,3	21,5	34	2,2	0	0	0
1	3	9	6	93,9	135,7	586,7	15,1	23,5	36	5,4	0	10,02	1
4	3	9	2	90,3	80,7	730,2	6,3	17,8	63	4,9	0	0	0
6	3	9	2	90,3	80,7	730,2	6,3	18,2	62	4,5	0	0	0
6	3	2	7	94,9	130,3	587,1	14,1	23,4	40	5,8	0	1,29	1
8	4	8	6	95,2	217,7	690	18	23,4	49	5,4	0	6,43	1
4	4	9	7	90,3	290	855,3	7,4	16,2	58	3,6	0	0	0
6	5	9	4	96	127,1	570,5	16,5	23,4	33	4,5	0	2,51	1
8	6	8	4	92,1	178	605,3	9,6	23,3	40	4	0	6,36	1
2	4	8	3	90,4	93,3	298,1	7,5	20,7	25	4,9	0	0	0
7	4	8	7	90,4	89,5	290,8	6,4	15,4	45	2,2	0	0	0
8	6	8	2	90,4	89,5	290,8	6,4	14,3	46	1,8	0	0,9	0
8	3	6	1	94,8	227	706,7	12	23,3	34	3,1	0	28,74	1
4	4	12	1	92,5	56,4	433,3	7,1	23,2	39	5,4	0	1,19	1
2	5	8	6	93,7	80,9	685,2	17,9	23,2	26	4,9	0	23,41	1
6	6	8	1	91,6	108,4	764	6,2	23	34	2,2	0	56,04	1
6	5	9	6	91,6	100,2	466,3	6,3	22,9	40	1,3	0	2,64	1
6	3	10	2	90,6	35,4	669,1	6,7	21,7	24	4,5	0	0	0
7	4	8	7	93,5	139,4	594,2	20,3	22,9	31	7,2	0	15,45	1
7	3	10	6	90,6	43,7	686,9	6,7	17,8	27	4	0	0	0
7	3	4	1	90,6	269,8	811,2	5,5	22,2	45	3,6	0	0	0
4	4	8	3	93,5	149,3	728,6	8,1	22,9	39	4,9	0	48,55	1
7	4	10	6	90,6	43,7	686,9	6,7	14,6	33	1,3	0	0	0
7	4	10	2	90,6	35,4	669,1	6,7	18	33	0,9	0	0	0
1	3	9	1	90,7	80,9	368,3	16,8	14,8	78	8	0	0	0
6	5	9	2	91,1	88,2	731,7	8,3	22,8	46	4	0	4,95	1
2	4	9	1	90,7	194,1	643	6,8	21,3	41	3,6	0	0	0
7	5	6	7	92,3	92,1	442,1	9,8	22,8	27	4,5	0	1,63	1
3	4	9	4	91,6	108,4	764	6,2	22,7	35	2,2	0	7,48	1
4	4	4	6	90,8	84,7	376,6	5,6	23,8	51	1,8	0	0	0
2	4	9	1	93,7	121,7	350,2	18	22,7	40	9,4	0	3,19	1
6	5	4	5	90,9	18,9	30,6	8	8,7	51	5,8	0	0	0
2	2	8	2	90,9	18,9	30,6	8	11,6	48	5,4	0	0	0
5	6	9	1	90,9	126,5	686,5	7	14,7	70	3,6	0	0	0
3	6	9	1	90,9	126,5	686,5	7	15,6	66	3,1	0	0	0
8	6	8	1	63,5	70,8	665,3	0,8	22,6	38	3,6	0	11,32	1

X	Y	month	day	FFMC	DMC	DC	ISI	temp	RH	wind	rain	area	Kelas
7	4	8	7	89,2	103,9	431,6	6,4	22,6	57	4,9	0	278,53	1
6	5	9	1	90,9	126,5	686,5	7	21,3	42	2,2	0	0	0
8	6	8	6	90,9	126,5	686,5	7	21,9	39	1,8	0	0,47	0
7	4	9	1	90,9	126,5	686,5	7	19,4	48	1,3	0	0	0
1	4	9	1	91,8	175,1	700,7	13,8	22,4	54	7,6	0	2,87	1
4	4	4	5	91	166,9	752,6	7,1	18,5	73	8,5	0	0	0
6	5	8	7	92,9	137	706,4	9,2	22,1	34	1,8	0	14,57	1
6	6	8	6	81,6	56,7	665,6	1,9	21,9	71	5,8	0	54,29	1
8	6	8	2	91	276,3	825,1	7,1	21,9	43	4	0	70,76	1
2	5	9	2	91	276,3	825,1	7,1	13,8	77	7,6	0	0	0
1	2	8	2	91	121,2	561,6	7	21,6	19	6,7	0	0	0
6	5	9	6	92,9	133,3	699,6	9,2	21,9	35	1,8	0	2,57	1
4	4	9	3	91	14,6	25,6	12,3	17,6	27	5,8	0	0	0
2	5	8	4	91	166,9	752,6	7,1	18,2	62	5,4	0	0,43	0
8	6	9	2	91	129,5	692,6	7	13,1	63	5,4	0	0	0
5	4	8	5	93,7	231,1	715,1	8,4	21,9	42	2,2	0	174,63	1
2	4	8	7	91	166,9	752,6	7,1	25,9	41	3,6	0	0	0
7	4	8	7	91	166,9	752,6	7,1	25,9	41	3,6	0	0	0
6	5	4	4	87,9	84,8	725,1	3,7	21,8	34	2,2	0	6,04	1
3	4	9	7	94,3	167,6	684,4	13	21,8	53	3,1	0	6,54	1
6	4	9	2	91	129,5	692,6	7	18,3	40	2,7	0	0	0
3	5	9	4	93,1	157,3	666,7	13,5	21,7	40	0,4	0	2,47	1
8	6	8	6	91	129,5	692,6	7	21,6	33	2,2	0	11,53	1
6	3	9	5	92,8	119	783,5	7,5	21,6	28	6,3	0	4,41	1
6	3	8	4	91	129,5	692,6	7	21,7	38	2,2	0	0,43	0
4	5	8	3	91,2	124,4	795,3	8,5	21,5	28	4,5	0	15,64	1
7	4	9	4	92,9	137	706,4	9,2	21,5	15	0,9	0	11,06	1
7	4	9	5	91,1	94,1	232,1	7,1	19,2	38	4,5	0	0	0
7	4	4	1	91,1	94,1	232,1	7,1	19,2	38	4,5	0	0	0
4	4	9	5	91,6	112,4	573	8,9	21,4	42	3,1	0	4,25	1
7	4	7	6	91,9	109,2	565,5	8	21,4	38	2,7	0	1,52	1
8	6	8	5	91,1	132,3	812,1	12,5	16,4	27	3,6	0	0	0
2	2	8	1	91,1	103,2	638,8	5,8	23,1	31	3,1	0	0	0
6	3	4	7	91,5	130,1	807,1	7,5	21,3	35	2,2	0	28,19	1
8	6	8	1	91,1	103,2	638,8	5,8	23,4	22	2,7	0	0	0
8	5	8	3	91,1	91,3	738,1	7,2	19,1	46	2,2	0	0,33	0
1	3	9	5	91,6	273,8	819,1	7,7	21,3	44	4,5	0	12,18	1
4	5	4	5	91,2	48,3	97,8	12,5	15,8	27	7,6	0	0	0
8	6	9	4	91,2	183,1	437,7	12,5	12,6	90	7,6	0,2	0	0
8	6	8	4	81,6	56,7	665,6	1,9	21,2	70	6,7	0	11,16	1
4	5	9	4	91	166,9	752,6	7,1	21,1	71	7,6	1,4	2,17	1
2	4	9	6	91,2	147,8	377,2	12,7	19,6	43	4,9	0	0	0

X	Y	month	day	FFMC	DMC	DC	ISI	temp	RH	wind	rain	area	Kelas
5	4	8	4	91,9	111,7	770,3	6,5	21,1	35	2,7	0	5,65	1
6	5	9	6	92,5	122	789,7	10,2	21,1	39	2,2	0	8,12	1
4	4	8	2	91,2	94,3	744,4	8,4	22,3	48	4	0	0,72	0
6	5	4	5	91,2	134,7	817,5	7,2	18,5	30	2,7	0	0	0
5	6	8	7	90,9	126,5	686,5	7	21	42	2,2	0	7,3	1
1	4	8	5	91,6	181,3	613	7,6	20,9	50	2,2	0	16	1
1	2	8	7	91,4	142,4	601,4	10,6	19,5	39	6,3	0	0	0
7	4	9	3	93,6	235,1	723,1	10,1	20,9	66	4,9	0	15,34	1
6	5	4	1	92,1	99	745,3	9,6	20,8	35	4,9	0	13,06	1
3	4	8	7	91,4	142,4	601,4	10,6	19,8	39	5,4	0	0	0
3	4	8	7	91,4	142,4	601,4	10,6	19,8	39	5,4	0	0	0
7	4	8	7	91,4	142,4	601,4	10,6	16,3	60	5,4	0	0	0
8	6	8	7	91,4	142,4	601,4	10,6	18,2	43	4,9	0	0	0
3	4	8	7	91,4	142,4	601,4	10,6	11,6	87	4,5	0	0	0
3	5	10	3	91,4	37,9	673,8	5,2	15,9	46	3,6	0	0	0
4	5	4	4	91,4	30,7	74,3	7,5	18,2	29	3,1	0	0	0
6	5	12	2	92,1	99	745,3	9,6	20,8	35	4,9	0	1,26	1
3	4	8	1	91,5	145,4	608,2	10,7	17,1	43	5,4	0	0	0
1	3	9	7	93,9	135,7	586,7	15,1	20,8	34	4,9	0	6,96	1
3	4	8	4	91	129,5	692,6	7	20,7	37	2,2	0	17,2	1
2	2	7	5	91,5	238,2	730,6	7,5	17,7	65	4	0	0	0
4	3	6	4	91,1	91,3	738,1	7,2	20,7	46	2,7	0	30,18	1
5	4	9	6	95,2	131,7	578,8	10,4	20,7	45	2,2	0	2,55	1
3	4	8	1	91,5	145,4	608,2	10,7	10,3	74	2,2	0	0	0
8	6	8	1	91,5	145,4	608,2	10,7	8	86	2,2	0	0	0
8	6	8	2	91,5	130,1	807,1	7,5	20,6	37	1,8	0	0	0
6	5	2	2	90,5	96,7	750,5	11,4	20,6	55	5,4	0	24,59	1
6	3	9	7	92,1	99	745,3	9,6	20,6	43	3,6	0	2,03	1
1	4	8	6	91,6	108,4	764	6,2	18	51	5,4	0	0	0
4	3	4	1	91,6	181,3	613	7,6	19,3	61	4,9	0	0	0
5	4	8	2	91,6	248,4	753,8	6,3	20,5	58	2,7	0	42,87	1
6	4	6	7	92,1	111,2	654,1	9,6	20,5	35	4	0	1,64	1
3	4	9	5	90,5	96,7	750,5	11,4	20,4	55	4,9	0	3,64	1
7	4	7	6	91,6	108,4	764	6,2	20,4	41	1,8	0	1,47	1
1	4	9	5	90,2	96,9	624,2	8,9	20,3	39	4,9	0	4,53	1
3	6	6	5	95,2	131,7	578,8	10,4	20,3	41	4	0	1,9	1
4	4	9	7	91,6	248,4	753,8	6,3	16,8	56	3,1	0	0	0
1	2	7	5	91,4	37,9	673,8	5,2	20,2	37	2,7	0	13,7	1
6	5	6	5	91,6	104,2	474,9	9	22,1	49	2,7	0	0	0
8	6	8	6	91,6	248,4	753,8	6,3	16,6	59	2,7	0	0	0
6	3	9	1	92,1	152,6	658,2	14,3	20,2	47	4	0	3,09	1
3	3	9	6	91,4	142,4	601,4	10,6	20,1	39	5,4	0	2,74	1

X	Y	month	day	FFMC	DMC	DC	ISI	temp	RH	wind	rain	area	Kelas
8	6	8	4	92,1	152,6	658,2	14,3	20,1	58	4,5	0	9,27	1
4	5	8	1	92,2	81,8	480,8	11,9	20,1	34	4,5	0	58,3	1
2	5	8	7	91,6	108,4	764	6,2	19,3	44	2,2	0	0	0
6	5	9	5	91,6	248,4	753,8	6,3	20,4	56	2,2	0	0	0
8	3	9	4	91,6	248,4	753,8	6,3	20,4	56	2,2	0	0	0
6	5	4	1	94,3	85,1	692,3	15,9	20,1	47	4,9	0	26,13	1
3	4	7	6	91,6	104,2	474,9	9	24,3	30	1,8	0	0	0
5	4	9	5	91,6	104,2	474,9	9	18,7	53	1,8	0	0	0
6	5	4	4	91,6	108,4	764	6,2	9,8	86	1,8	0	0	0
9	9	7	7	91,6	104,2	474,9	9	24,2	32	1,8	0	0	0
7	6	7	3	94,3	85,1	692,3	15,9	20,1	47	4,9	0	1,46	1
8	6	8	4	90,3	290	855,3	7,4	19,9	44	3,1	0	7,8	1
3	4	4	6	91,7	35,8	80,8	7,8	11,6	30	6,3	0	0	0
5	4	4	5	91,7	33,3	77,5	9	15,6	25	6,3	0	0	0
5	5	4	6	91,7	35,8	80,8	7,8	15,1	27	5,4	0	0	0
8	6	4	5	91,7	35,8	80,8	7,8	17,4	24	5,4	0	0	0
4	4	8	2	91,7	191,4	635,9	7,8	19,9	50	4	0	82,75	1
6	5	6	6	92,1	99	745,3	9,6	19,8	47	2,7	0	1,72	1
3	4	4	6	91,7	35,8	80,8	7,8	15,2	27	4,9	0	0	0
6	5	4	6	91,7	35,8	80,8	7,8	17,4	25	4,9	0	0	0
4	5	7	5	92,6	115,4	777,1	8,8	19,7	41	1,8	0	1,58	1
8	6	8	7	91,4	142,4	601,4	10,6	19,6	41	5,8	0	196,48	1
2	2	8	4	91,7	114,3	661,3	6,3	18,6	44	4,5	0	0	0
3	4	4	5	91,7	33,3	77,5	9	18,8	18	4,5	0	0	0
4	5	4	5	91,7	33,3	77,5	9	17,2	26	4,5	0	0	0
8	6	8	6	91,9	111,7	770,3	6,5	19,6	45	3,1	0	20,03	1
1	4	8	3	92,4	117,9	668	12,2	19,6	33	6,3	0	19,23	1
8	6	4	5	91,7	33,3	77,5	9	8,3	97	4	0,2	0	0
1	2	8	4	91,7	114,3	661,3	6,3	20,2	45	3,6	0	0	0
4	3	8	4	91,7	114,3	661,3	6,3	17,6	45	3,6	0	0	0
6	3	9	7	91,7	75,6	718,3	7,8	17,7	39	3,6	0	0	0
4	3	7	4	92,9	133,3	699,6	9,2	19,4	19	1,3	0	31,72	1
1	2	8	3	91,8	175,1	700,7	13,8	21,9	73	7,6	1	0	0
2	2	8	2	91,8	175,1	700,7	13,8	26,8	38	6,3	0	0,76	0
2	4	8	3	91,8	175,1	700,7	13,8	25,7	39	5,4	0	0,09	0
3	4	9	1	91,8	78,5	724,3	9,2	18,9	35	2,7	0	0	0
5	4	9	1	91,8	78,5	724,3	9,2	19,1	38	2,7	0	0	0
6	3	9	1	91,8	78,5	724,3	9,2	21,2	32	2,7	0	0	0
4	4	8	3	95,1	141,3	605,8	17,7	19,4	71	7,6	0	46,7	1
2	5	8	3	91,8	170,9	692,3	13,7	20,6	59	0,9	0	0	0
8	6	4	7	91,9	133,6	520,5	8	14,2	58	4	0	0	0
9	4	7	6	91,1	141,1	629,1	7,1	19,3	39	3,6	0	1,56	1

X	Y	month	day	FFMC	DMC	DC	ISI	temp	RH	wind	rain	area	Kelas
7	4	9	5	91,6	108,4	764	6,2	19,3	44	2,2	0	3,93	1
9	9	8	5	93,7	101,3	458,8	11,9	19,3	39	7,2	0	7,73	1
7	4	9	5	90,2	99,6	631,2	6,3	19,2	44	2,7	0	4,69	1
2	5	9	3	91,9	111,7	770,3	6,5	15,7	51	2,2	0	0	0
4	4	9	5	92,4	96,2	739,4	8,6	19,2	24	4,9	0	3,78	1
6	5	4	1	92	203,2	664,5	8,1	19,1	70	2,2	0	0	0
1	5	9	1	92	203,2	664,5	8,1	10,4	75	0,9	0	0	0
3	4	7	3	84,9	32,8	664,2	3	19,1	32	4	0	5,44	1
1	4	9	1	90,4	93,3	298,1	7,5	19,1	39	5,4	0	3,52	1
4	4	9	5	92,1	152,6	658,2	14,3	19,1	53	2,7	0	4,4	1
4	3	8	3	92,1	111,2	654,1	9,6	20,4	42	4,9	0	0	0
4	3	8	3	92,1	111,2	654,1	9,6	20,4	42	4,9	0	0	0
8	6	6	3	92,4	117,9	668	12,2	19	34	5,8	0	1,69	1
8	6	10	1	92,1	99	745,3	9,6	17,4	57	4,5	0	0	0
8	6	8	4	91,6	138,1	621,7	6,3	18,9	41	3,1	0	10,34	1
7	4	7	1	92,8	119	783,5	7,5	18,9	34	7,2	0	34,36	1
6	3	9	1	93,7	231,1	715,1	8,4	18,9	64	4,9	0	3,32	1
2	4	8	7	91	129,5	692,6	7	18,8	40	2,2	0	212,88	1
1	2	8	5	91	129,5	692,6	7	18,7	43	2,7	0	103,39	1
2	2	8	6	92,1	99	745,3	9,6	18,7	50	2,2	0	5,97	1
9	9	7	4	93,3	141,2	713,9	13,9	18,6	49	3,6	0	35,88	1
1	3	9	7	92,1	99	745,3	9,6	10,1	75	3,6	0	0	0
8	6	8	6	90,6	43,7	686,9	6,7	18,4	25	3,1	0	24,23	1
4	3	8	6	92,1	152,6	658,2	14,3	21,8	56	3,1	0	0,52	0
5	4	4	1	92,1	152,6	658,2	14,3	21	32	3,1	0	0	0
6	5	8	4	92,1	152,6	658,2	14,3	23,7	24	3,1	0	0	0
8	6	7	2	92,1	111,2	654,1	9,6	18,4	45	3,6	0	1,63	1
4	4	12	1	92,5	122	789,7	10,2	18,4	42	2,2	0	1,09	1
4	3	9	2	90,1	82,9	735,7	6,2	18,3	45	2,2	0	4,88	1
4	3	8	7	92,5	121,1	674,4	8,6	18,2	46	1,8	0	200,94	1
7	4	4	7	92,1	207	672,6	8,2	21,1	54	2,2	0	0	0
5	4	9	4	93,7	101,3	423,4	14,7	18,2	82	4,5	0	2,21	1
7	4	8	6	92,1	207	672,6	8,2	26,8	35	1,3	0	0,54	0
6	5	9	3	92,1	87,7	721,1	9,5	18,1	54	3,1	0	2,13	1
1	2	8	3	92,1	111,2	654,1	9,6	16,6	47	0,9	0	0	0
2	5	8	7	89,6	25,4	73,7	5,7	18	40	4	0	38,48	1
7	4	9	7	89,7	90	704,4	4,8	17,8	67	2,2	0	2,01	1
3	4	9	7	92,5	121,1	674,4	8,6	17,8	56	1,8	0	1,95	1
7	4	9	1	90,9	126,5	686,5	7	17,7	39	2,2	0	3,07	1
7	4	8	7	92,2	102,3	751,5	8,4	24,1	27	3,1	0	0	0
8	6	8	3	92,2	102,3	751,5	8,4	24,2	27	3,1	0	0	0
6	5	8	2	92,2	91,6	503,6	9,6	20,7	70	2,2	0	0,75	0

X	Y	month	day	FFMC	DMC	DC	ISI	temp	RH	wind	rain	area	Kelas
4	4	9	1	92,2	102,3	751,5	8,4	21,2	32	2,2	0	0	0
1	4	8	6	92,2	102,3	751,5	8,4	19,7	35	1,8	0	0	0
8	6	8	7	92,3	85,3	488	14,7	20,8	32	6,3	0	0	0
7	4	2	7	92,3	96,2	450,2	12,1	23,4	31	5,4	0	0	0
8	6	8	7	92,3	85,3	488	14,7	22,2	29	5,4	0	0	0
1	2	8	5	92,5	121,1	674,4	8,6	17,7	25	3,1	0	154,88	1
6	5	2	1	91	129,5	692,6	7	17,6	46	3,1	0	7,04	1
8	6	8	1	92,3	88,9	495,6	8,5	24,1	27	3,1	0	0	0
4	3	9	6	85,6	90,4	609,6	6,6	17,4	50	4	0	2,69	1
4	6	12	4	94,8	108,3	647,1	17	17,4	43	6,7	0	1,07	1
2	2	9	5	92,4	117,9	668	12,2	19,6	33	6,3	0	0	0
7	4	9	5	92,5	122	789,7	10,2	17,3	45	4	0	3,94	1
7	4	9	5	92,4	117,9	668	12,2	19	34	5,8	0	0	0
8	6	8	4	92,4	96,2	739,4	8,6	18,6	24	5,8	0	0	0
2	2	9	5	92,4	117,9	668	12,2	19,6	33	5,4	0	0	0
3	4	9	7	92,4	124,1	680,7	8,5	22,5	42	5,4	0	0	0
1	4	8	5	91,2	124,4	795,3	8,5	17,1	41	2,2	0	11,22	1
2	2	9	5	92,4	117,9	668	12,2	23	37	4,5	0	0	0
6	5	4	4	92,4	105,8	758,1	9,9	25,3	27	2,7	0	0	0
8	5	9	7	92,4	105,8	758,1	9,9	24,9	27	2,2	0	0	0
5	5	4	4	92,3	88,8	440,9	8,5	17,1	67	3,6	0	6,57	1
8	6	9	6	92,4	105,8	758,1	9,9	16	45	1,8	0	0	0
7	4	9	5	87,1	291,3	860,6	4	17	67	4,9	0	3,95	1
3	6	9	7	92,4	124,1	680,7	8,5	17,2	58	1,3	0	0	0
7	5	9	6	92,5	88	698,6	7,1	17,8	51	7,2	0	0	0
4	3	5	5	91,7	35,8	80,8	7,8	17	27	4,9	0	28,66	1
2	4	9	6	92,5	121,1	674,4	8,6	24,1	29	4,5	0	0	0
5	4	4	7	91,7	35,8	80,8	7,8	17	27	4,9	0	28,66	1
9	4	6	6	92,4	124,1	680,7	8,5	16,9	60	1,3	0	29,48	1
7	5	9	6	92,5	88	698,6	7,1	22,8	40	4	0	0	0
5	4	2	7	92,5	122	789,7	10,2	15,9	55	3,6	0	0	0
5	4	9	5	91,2	94,3	744,4	8,4	16,8	47	4,9	0	12,64	1
4	5	9	6	92,5	88	698,6	7,1	20,3	45	3,1	0	0	0
4	4	9	6	92,5	88	698,6	7,1	19,6	48	2,7	0	0	0
7	4	10	1	92,5	122	789,7	10,2	19,7	39	2,7	0	0	0
6	5	9	6	91,5	130,1	807,1	7,5	16,8	43	3,1	0	5,83	1
7	4	2	1	91,7	48,5	696,1	11,1	16,8	45	4,5	0	6,83	1
4	3	9	7	92,8	119	783,5	7,5	16,8	28	4	0	7,21	1
8	6	12	3	92,8	119	783,5	7,5	16,8	28	4	0	1,01	1
3	4	10	7	92,6	46,5	691,8	8,8	20,6	24	5,4	0	0	0
6	5	8	3	92,6	115,4	777,1	8,8	24,3	27	4,9	0	0	0
4	3	10	7	92,6	46,5	691,8	8,8	13,8	50	2,7	0	0	0

X	Y	month	day	FFMC	DMC	DC	ISI	temp	RH	wind	rain	area	Kelas
6	3	9	4	92,1	111,2	654,1	9,6	16,6	47	0,9	0	2,29	1
2	5	10	7	92,6	46,5	691,8	8,8	15,4	35	0,9	0	0	0
7	5	8	2	92,2	81,8	480,8	11,9	16,4	43	4	0	71,3	1
2	5	7	6	94,8	108,3	647,1	17	16,4	47	1,3	0	1,56	1
7	4	7	7	90,2	99,6	631,2	6,3	16,2	59	3,1	0	32,07	1
2	4	8	3	90,3	290	855,3	7,4	16,2	58	3,6	0	9,96	1
7	4	8	1	90,7	194,1	643	6,8	16,2	63	2,7	0	16,33	1
7	5	9	6	92,8	73,2	713	22,6	19,3	38	4	0	0	0
5	4	9	3	92,8	119	783,5	7,5	21,6	27	2,2	0	0	0
6	5	6	1	90,1	39,7	86,6	6,2	16,1	29	3,1	0	1,75	1
6	5	9	3	92,9	133,3	699,6	9,2	26,4	21	4,5	0	0	0
4	4	8	4	91,7	48,5	696,1	11,1	16,1	44	4	0	49,37	1
1	2	9	4	92,9	137	706,4	9,2	25,4	27	2,2	0	0	0
1	2	9	4	92,9	137	706,4	9,2	22,4	34	2,2	0	0	0
4	3	9	4	92,9	137	706,4	9,2	27,7	24	2,2	0	0	0
6	5	6	1	91,1	132,3	812,1	12,5	15,9	38	5,4	0	1,75	1
6	5	9	4	91,5	130,1	807,1	7,5	15,9	51	4,5	0	2,18	1
2	3	9	1	91,9	111,7	770,3	6,5	15,9	53	2,2	0	2,93	1
4	4	9	4	92,9	137	706,4	9,2	20,8	17	1,3	0	0	0
1	4	9	7	91,6	273,8	819,1	7,7	15,5	72	8	0	1,94	1
1	2	9	4	92,9	137	706,4	9,2	21,5	15	0,9	0	0	0
2	2	8	4	93	75,3	466,6	7,7	18,8	35	4,9	0	0	0
3	4	8	4	93	75,3	466,6	7,7	19,6	36	3,1	0	0	0
8	6	8	7	90,1	82,9	735,7	6,2	15,4	57	4,5	0	37,71	1
2	4	8	1	91,2	94,3	744,4	8,4	15,4	57	4,9	0	39,35	1
3	4	8	3	93,1	157,3	666,7	13,5	22,1	37	3,6	0	0,21	0
2	4	8	5	93,1	157,3	666,7	13,5	26,8	25	3,1	0	0,68	0
8	5	8	3	93,1	157,3	666,7	13,5	24	36	3,1	0	0,24	0
8	6	8	5	93,1	157,3	666,7	13,5	28,7	28	2,7	0	0	0
1	5	9	6	93,1	180,4	430,8	11	22,2	48	1,3	0	0	0
1	2	8	6	92,1	99	745,3	9,6	15,4	53	6,3	0	7,31	1
1	5	9	7	93,2	114,4	560	9,5	30,2	22	4,9	0	0	0
2	2	8	4	94,2	122,3	589,9	12,9	15,4	66	4	0	10,13	1
6	5	9	5	93,3	141,2	713,9	13,9	22,9	44	5,4	0	0	0
4	3	7	7	90,1	39,7	86,6	6,2	15,2	27	3,1	0	31,86	1
4	5	9	4	93,3	49,5	297,7	14	28	34	4,5	0	0	0
6	5	5	6	90,6	50,1	100,4	7,8	15,2	31	8,5	0	1,94	1
5	4	9	5	93,3	141,2	713,9	13,9	27,6	30	1,3	0	0	0
8	6	8	7	93,4	17,3	28,3	9,9	8,9	35	8	0	0	0
2	2	8	2	93,4	15	25,6	11,4	15,2	19	7,6	0	0	0
2	2	8	6	93,4	17,3	28,3	9,9	13,8	24	5,8	0	0	0
2	5	9	5	90,6	50,1	100,4	7,8	15,1	64	4	0	13,99	1

X	Y	month	day	FFMC	DMC	DC	ISI	temp	RH	wind	rain	area	Kelas
6	3	9	6	93,4	145,4	721,4	8,1	30,2	24	2,7	0	0	0
1	4	9	6	91,2	48,3	97,8	12,5	14,6	26	9,4	0	2,53	1
5	4	9	5	91	276,3	825,1	7,1	14,5	76	7,6	0	3,71	1
4	5	9	2	88,8	147,3	614,5	9	14,4	66	5,4	0	5,23	1
3	5	8	6	93,5	139,4	594,2	20,3	17,6	52	5,8	0	0	0
7	4	8	6	93,5	139,4	594,2	20,3	23,7	32	5,8	0	0	0
7	4	9	7	88,2	96,2	229	4,7	14,3	79	4	0	1,94	1
1	2	9	7	93,5	149,3	728,6	8,1	25,3	36	3,6	0	0	0
6	3	9	7	93,5	149,3	728,6	8,1	22,8	39	3,6	0	0	0
2	2	9	1	90,2	96,9	624,2	8,9	14,2	53	1,8	0	3,5	1
2	5	7	6	91	129,5	692,6	7	13,9	59	6,3	0	11,24	1
3	5	9	5	93,5	149,3	728,6	8,1	17,2	43	3,1	0	0	0
1	3	8	6	91	276,3	825,1	7,1	13,8	77	7,6	0	11,06	1
6	3	9	5	88,1	53,3	726,9	5,4	13,7	56	1,8	0	4,42	1
3	4	8	2	91	14,6	25,6	12,3	13,7	33	9,4	0	61,13	1
4	5	9	4	93,6	235,1	723,1	10,1	24,1	50	4	0	0	0
3	4	8	7	88,3	150,3	309,9	6,8	13,4	79	3,6	0	37,02	1
4	4	8	2	93,7	102,2	550,3	14,6	22,1	54	7,6	0	0,79	0
9	5	6	3	90,8	41,9	89,4	7,9	13,3	42	0,9	0	7,4	1
7	4	8	5	91,3	20,6	43,5	8,5	13,3	27	3,6	0	6,61	1
4	4	9	4	90,7	136,9	822,8	6,8	12,9	39	2,7	0	2,18	1
4	6	9	7	93,7	231,1	715,1	8,4	18,9	64	4,9	0	0	0
8	6	8	6	93,7	231,1	715,1	8,4	18,9	64	4,9	0	0	0
8	6	6	7	92,1	99	745,3	9,6	12,8	64	3,6	0	1,64	1
8	6	8	3	86,8	15,6	48,3	3,9	12,4	53	2,2	0	6,38	1
2	5	6	4	88,6	91,8	709,9	7,1	12,4	73	6,3	0	30,32	1
2	5	8	6	90,1	37,6	83,7	7,2	12,4	54	3,6	0	12,1	1
4	5	1	7	91,5	130,1	807,1	7,5	12,2	66	4,9	0	6,1	1
5	6	4	6	93,7	231,1	715,1	8,4	26,4	33	3,6	0	0	0
4	6	9	4	93,7	80,9	685,2	17,9	17,6	42	3,1	0	0	0
6	5	4	4	93,7	231,1	715,1	8,4	25,9	32	3,1	0	0	0
2	4	8	7	90,5	196,8	649,9	16,3	11,8	88	4,9	0	9,71	1
2	2	8	2	93,9	169,7	411,8	12,3	23,4	40	6,3	0	0	0
1	4	7	2	91,2	48,3	97,8	12,5	11,7	33	4	0	8,31	1
4	5	2	7	89,3	51,3	102,2	9,6	11,5	39	5,8	0	7,19	1
4	5	9	3	94	47,9	100,7	10,7	17,3	80	4,5	0	0	0
4	3	9	5	90,7	44	92,4	5,5	11,5	60	4	0	8,24	1
6	6	7	1	94,2	62,3	442,9	11	23	36	3,1	0	0	0
6	3	8	5	94,2	117,2	581,1	11	21,4	44	2,7	0	0,68	0
4	5	8	7	90,2	18,5	41,1	7,3	11,2	41	5,4	0	5,55	1
3	4	9	5	94,3	85,1	692,3	15,9	19,8	50	5,4	0	0	0
8	6	9	1	91,6	112,4	573	8,9	11,2	84	7,6	0	3,3	1

X	Y	month	day	FFMC	DMC	DC	ISI	temp	RH	wind	rain	area	Kelas
4	3	7	4	87,6	52,2	103,8	5	11	46	5,8	0	36,85	1
7	4	6	7	94,3	96,3	200	56,1	21	44	4,5	0	0	0
8	6	8	3	94,3	131,7	607,1	22,7	19,4	55	4	0	0,17	0
5	6	9	3	94,3	85,1	692,3	15,9	25,9	24	4	0	0	0
4	5	9	5	94,3	85,1	692,3	15,9	17,7	37	3,6	0	0	0
6	3	9	5	94,3	85,1	692,3	15,9	25,4	24	3,6	0	0	0
6	5	4	4	87,6	52,2	103,8	5	11	46	5,8	0	27,35	1
3	4	8	7	94,4	146	614,7	11,3	25,6	42	4	0	0	0
6	3	9	1	87,9	24,9	41,6	3,7	10,9	64	3,1	0	3,35	1
2	4	8	4	90,3	290	855,3	7,4	10,3	78	4	0	18,3	1
7	5	10	1	94,6	160	567,2	16,7	17,9	48	2,7	0	0	0
1	5	9	2	94,6	212,1	680,9	9,5	27,9	27	2,2	0	0	0
8	6	9	1	87,2	15,1	36,9	7,1	10,2	45	5,8	0	3,18	1
7	4	9	5	94,8	222,4	698,6	13,9	23,9	38	6,7	0	0	0
4	4	10	6	94,8	222,4	698,6	13,9	26,2	34	5,8	0	0	0
4	4	8	2	94,8	108,3	647,1	17	16,6	54	5,4	0	0	0
1	3	8	5	85	9	56,9	3,5	10,1	62	1,8	0	51,78	1
5	4	9	5	92,1	99	745,3	9,6	10,1	75	3,6	0	3,71	1
8	6	8	1	83,9	8,7	32,1	2,1	8,8	68	2,2	0	13,05	1
1	2	8	2	94,8	108,3	647,1	17	18,6	51	4,5	0	0	0
2	4	8	2	94,8	108,3	647,1	17	20,1	40	4	0	0	0
3	4	9	2	94,8	227	706,7	12	25	36	4	0	0	0
3	4	12	1	86,9	6,6	18,7	3,2	8,8	35	3,1	0	1,1	1
4	5	9	3	94,8	227	706,7	12	23,3	34	3,1	0	0	0
6	4	4	6	94,8	222,4	698,6	13,9	20,3	42	2,7	0	0	0
4	3	9	5	84,6	3,2	43,6	3,3	8,2	53	9,4	0	4,62	1
8	8	8	3	84,7	9,5	58,3	4,1	7,5	71	6,3	0	9,96	1
6	4	9	2	94,9	130,3	587,1	14,1	31	27	5,4	0	0	0
1	4	9	7	85,2	4,9	15,8	6,3	7,5	46	8	0	24,24	1
3	4	8	7	81,5	9,1	55,2	2,7	5,8	54	5,8	0	10,93	1
6	5	9	5	81,5	9,1	55,2	2,7	5,8	54	5,8	0	4,61	1
4	4	9	3	84,9	18,2	55	3	5,3	70	4,5	0	2,14	1
4	5	9	6	95,1	141,3	605,8	17,7	28,7	33	4	0	0	0
3	4	9	3	75,1	4,4	16,2	1,9	5,1	77	5,4	0	2,14	1
9	4	9	2	95,1	141,3	605,8	17,7	20,6	58	1,3	0	0	0
2	4	8	7	84	27,8	354,6	5,3	5,1	61	8	0	11,19	1
7	5	9	2	95,2	217,7	690	18	30,8	19	4,5	0	0	0
4	5	9	7	84,6	26,4	352	2	5,1	61	4,9	0	5,38	1
2	2	8	2	95,2	131,7	578,8	10,4	27,4	22	4	0	0,9	0
6	4	2	2	85,4	25,4	349,7	2,6	5,1	24	8,5	0	24,77	1
2	2	2	6	93,5	139,4	594,2	20,3	5,1	96	5,8	0	26	1
5	4	8	7	84,4	27,2	353,5	6,8	4,8	57	8,5	0	8,98	1

X	Y	month	day	FFMC	DMC	DC	ISI	temp	RH	wind	rain	area	Kelas
3	4	8	2	95,5	99,9	513,3	13,2	23,8	32	5,4	0	0,77	0
2	4	8	1	95,5	99,9	513,3	13,2	23,3	31	4,5	0	0,55	0
8	6	8	7	95,8	152	624,1	13,8	32,4	21	4,5	0	0	0
7	4	9	7	75,1	4,4	16,2	1,9	4,6	82	6,3	0	5,39	1
2	2	9	6	95,9	158	633,6	11,3	32,4	27	2,2	0	0	0
8	6	9	5	79,5	3,6	15,3	1,8	4,6	59	0,9	0	6,84	1
7	4	8	6	85,4	25,4	349,7	2,6	4,6	21	8,5	0	22,03	1
3	4	7	1	85,4	25,4	349,7	2,6	4,6	21	8,5	0	17,85	1
6	5	9	6	96,1	181,1	671,2	14,3	21,6	65	4,9	0,8	0	0
6	3	4	3	96,1	181,1	671,2	14,3	20,7	69	4,9	0,4	0	0
7	5	4	7	96,1	181,1	671,2	14,3	21,6	65	4,9	0,8	0	0
2	4	8	1	85,4	25,4	349,7	2,6	4,6	21	8,5	0	10,73	1
2	5	8	7	85,4	25,4	349,7	2,6	4,6	21	8,5	0	9,77	1
6	3	7	2	84,7	26,7	352,6	4,1	2,2	59	4,9	0	9,27	1
1	2	9	2	96,2	175,5	661,8	16,8	23,9	42	2,2	0	0	0

Lampiran 2 Kuesioner Pengujian *Prototype*

KUESIONER PERANGKAT LUNAK OPTIMASI NAÏVE BAYES MENGGUNAKAN GENETICA ALGORITHM UNTUK PREDIKSI KEBAKARAN HUTAN

Bapak/Ibu yang saya hormati,

Saya mahasiswa pascasarjana Nusa Mandiri Jakarta jurusan Ilmu Komputer. Dalam hal ini saya sedang melakukan penelitian *thesis*. Kuesioner ini merupakan instrumen yang saya gunakan untuk mengumpulkan data dalam rangka memperoleh Tanggapan terhadap penerapan aplikasi diagnosa tingkat kesuburan yang saya buat.

Atas bantuan, kesediaan waktu dan kerjasamanya, saya ucapkan terima kasih.

ANGKET INSTRUMEN PENELITIAN

- Petunjuk pengisian : berilah tanda ☒ *checklist* pada *checkbox* yang anda pilih

A. IDENTITAS RESPONDEN

(Responden tidak perlu menulis nama)

1. No responden : (* diisi oleh peneliti)
2. Jenis kelamin : ☐ Wanita ☐ Pria
3. Jabatan/Profesi :
4. Lama bekerja : ☐ < 1 Tahun ☐ 1-5 Tahun
☐ 5-10 Tahun ☐ 11-20 Tahun
☐ >20 Tahun
5. Pendidikan terakhir : ☐ Diploma ☐ S1
☐ S2 ☐ S3

B. PETUNJUK PENILAIAN KUESIONER

Berilah nilai disebelah kanan secara jujur tentang penilaian perangkat lunak dengan range penilaian 1-100, dimana semaihin nilainya besar maka diartikan bahwa perangkat lunak yang digunakan layak dan baik.

No	Metrik	Deskripsi	Bobot
1	<i>Auditability</i>	Memenuhi standard atau tidak	
2	<i>Accuracy</i>	Keakuratan komputasi	
3	<i>Completeness</i>	Kelengkapan	
4	<i>Error Tolerance</i>	Toleransi terhadap kesalahan	
5	<i>Execution Efficiency</i>	Kinerja Eksekusi	
6	<i>Operability</i>	Kemudahan untuk dioperasikan	
7	<i>Simplicity</i>	Kemudahan untuk difahami	
8	<i>Training</i>	Kemudahan pembelajaran fasilitas	

Jakarta, 05 Maret 2015

Penilaian

(.....)